

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

HODNOCENÍ KVALITY SPÁNKU

SLEEP QUALITY ASSESSMENT

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Daniela Dokoupilová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina, Ph.D.

BRNO 2021

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Daniela Dokoupilová

ID: 211197

Ročník: 3

Akademický rok: 2020/21

NÁZEV TÉMATU:

Hodnocení kvality spánku

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši v oblasti využití jednoduše měřitelných biosignálů (např. EKG, data z akcelerometru, fotoplethysmografická křivka, aj.) pro hodnocení kvality spánku. Popište metriky pro hodnocení kvality spánku a konkrétní metody analýzy dat používané v této oblasti. U jednotlivých metod uveďte jejich výhody/nevýhody v porovnání s konvenčním PSG přístupem. 2) Využijte veřejně dostupné databáze spánkových dat a vytvořte dvě množiny dat vhodné pro trénování a testování algoritmů. 3) Navrhněte a implementujte ve vhodném programovém prostředí postup pro analýzu vybraných signálů (včetně předzpracování dat, odvození příznaků vhodných pro detekci spánku, algoritmus pro samotnou detekci a výpočet výsledných metrik pro odhad kvality spánku měřených osob). 4) Otestujte navrženou metodu na reálných záznamech a statisticky vyhodnoťte její účinnost. 5) Na základě předchozího bodu proveďte optimalizaci postupu pro dosažení co nejlepších výsledků. 6) Dosažené výsledky vhodně interpretujte. Popište, ve kterých případech metoda chybovala a proč. 7) Porovnejte dosažené výsledky s údaji z literatury. Diskutujte výhody/nevýhody a možnosti vylepšení navrženého postupu.

DOPORUČENÁ LITERATURA:

- [1] ZAMBOTTI, M., et al. Wearable sleep technology in clinical and research settings. *Med Sci Sports Exerc*, 2019, vol. 51, pp 1538-1557.
- [2] WALCH, O., et al. Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device. *SLEEP*, 2019, vol. 42, pp 1-19.
- [3] SCHERZ, W.D., et al. Heart rate spectrum analysis for sleep quality detection. *EURASIP Journal on Embedded Systems*, 2017, 26.

Termín zadání: 8.2.2021

Termín odevzdání: 28.5.2021

Vedoucí práce: Ing. Marina Ronzhina, Ph.D.

doc. Ing. Jana Kolářová, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Abstrakt

Tato bakalářská práce se věnuje klasifikaci spánkových dat naměřených pomocí chytrých hodinek Apple Watch. Z využívaných signálů – tepové frekvence a akcelerometrického záznamu byly pomocí statistického testování vybrány příznaky pro klasifikaci spánkových epoch. Pro klasifikaci byla zvolena metoda podpůrných vektorů. Model byl poté natrénován pro rozpoznávání fáze Wake a Sleep a poté i pro rozpoznávání REM a NREM spánku. Klasifikace dat do dvou fází překročila hranici přesnosti 80 %, klasifikace Wake, REM a NREM spánku poté 58 %. Vypočtené parametry hodnotící kvalitu spánku byly poté srovnány s daty ohodnocenými spánkovým expertem. Model pro klasifikaci bdění a spánku se velmi přiblížil hodnocení experta. Model pro klasifikaci bdění, REM a NREM spánku se nejvíce lišil v parametrech hodnotících bdění.

Klíčová slova

spánek, chytré hodinky, klasifikace, SVM, hodnocení kvality spánku

Abstract

The topic of this bachelor thesis is quality sleep assessment using signals acquired from Apple Watch. From measured signals – heart rate and motion, were extracted parameters for sleep classification using statistical testing. These parameters were later used for training the support vector machine model. The model was first trained to classify Wake and Sleep, then also to classify Wake, REM and NREM stages. The accuracy of Wake/Sleep classification was about 80 %. The accuracy of Wake/REM/NREM classification exceeded 58 %. Finally, sleep quality parameters were calculated and compared to the data rated by a sleep expert. The outcome for Wake/Sleep classification was close to the expert evaluation. The model for Wake/REM/NREM classification was less accurate and differed mainly in parameters concerning Wake stage.

Keywords

sleep, smartwatch, classification, SVM, sleep quality assessment

Bibliografická citace:

DOKOUPILOVÁ, Daniela. *Hodnocení kvality spánku* [online]. Brno, 2021 [cit. 2021-05-25]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/134397>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Marina Ronzhina.

Prohlášení autora o původnosti díla

| | |
|-----------------------------------|---------------------------------|
| Jméno a příjmení studenta: | Daniela Dokoupilová |
| VUT ID studenta: | 211197 |
| Typ práce: | Bakalářská práce |
| Akademický rok: | 2020/21 |
| Téma závěrečné práce: | Hodnocení kvality spánku |

Prohlašuji, že svou závěrečnou práci jsem vypracovala samostatně pod vedením vedoucí závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne: 28. května 2021

podpis autora

Poděkování

Děkuji vedoucí bakalářské práce Ing. Marině Ronzhině, PhD. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

V Brně dne: 28. května 2021

.....
podpis autora

Obsah

| | |
|---|----|
| ÚVOD | 1 |
| 1. Fyziologie spánku | 2 |
| 1.1 Spánkové fáze a jejich projevy v biologických signálech | 2 |
| 1.2 Poruchy spánku | 3 |
| 2. METODY MONITOROVÁNÍ SPÁNKU | 4 |
| 2.1 Dotazníky | 4 |
| 2.2 Polysomnografie | 4 |
| 2.3 Aktigrafie | 5 |
| 3. AUTOMATICKÉ HODNOCENÍ SPÁNKOVÝCH DAT | 7 |
| 3.1 Metoda k-středů | 7 |
| 3.2 Náhodný les..... | 8 |
| 3.3 Neuronová síť..... | 9 |
| 3.4 Support Vector Machines..... | 10 |
| 4. ANALÝZA REÁLNÝCH SPÁNKOVÝCH DAT | 12 |
| 4.1 Protokol měření..... | 12 |
| 4.2 Popis naměřených dat | 13 |
| 4.3 Předzpracování dat | 14 |
| 5. PŘÍZNAKY PRO DETEKCI SPÁNKOVÝCH FÁZÍ | 17 |
| 5.1 Příznaky extrahované z tepové frekvence..... | 17 |
| 5.2 Příznaky extrahované z pohybu | 19 |
| 5.3 Transformace parametrů tepové frekvence | 21 |
| 5.4 Statistická analýza parametrů..... | 25 |
| 6. KLASIFIKACE SPÁNKOVÝCH EPOCH | 30 |
| 6.1 Binární klasifikace: Wake vs. Sleep..... | 30 |
| 6.2 Klasifikace fází Wake, REM a NREM | 36 |
| 6.2.1 Klasifikace fází Wake, REM a NREM metodou resubstituce..... | 39 |
| 7. HODNOCENÍ KVALITY SPÁNKU | 41 |
| 7.1 Hodnocení výstupů z klasifikace Wake a Sleep | 41 |
| 7.2 Hodnocení výstupů z klasifikace Wake, REM a NREM | 44 |
| 7.3 Hodnocení výstupů modelu využívajícího resubstituci | 49 |

Seznam symbolů a zkratek

Zkratky:

| | | |
|------|-----|---|
| EEG | ... | elektroenceelografie |
| EKG | ... | elektrokardiografie |
| EMG | ... | elektromyografie |
| EOG | ... | elektrookulografie |
| IQR | ... | interquartile range, mezikvartilové rozpětí |
| HF | ... | high frequency |
| HRV | ... | variabilita srdečního rytmu |
| LF | ... | low frequency, nízkofrekvenční pásmo |
| PVT | ... | psychomotoric vigilance test |
| PPG | ... | fotopletysmografie |
| REM | ... | rapid eye movements |
| RIP | ... | respirační indukční pletysmografie |
| SE | ... | efektivita spánku |
| SMA | ... | Signal Magnitude Area |
| SVM | ... | support vector machines, podpůrné vektory |
| TRT | ... | celkový čas záznamu |
| TST | ... | celkový čas spánku |
| TWT | ... | celkový čas vzhůru |
| VLf | ... | very low frequency, pásmo s velmi nízkými frekvencemi |
| WASO | ... | probuzení po počátku spánku |

Seznam obrázků

| | |
|--|----|
| Obr. 2-1 Hypnogram [4] | 5 |
| Obr. 2-2 Data nasnímaná pomocí aktigrafu [8] | 6 |
| Obr. 3-1 Znázornění průběhu algoritmu k-středů [14] | 7 |
| Obr. 3-2 Znázornění principu detekce spánkových fází s využitím rozhodovacího stromu | 8 |
| Obr. 3-3 Model neuronu [17]..... | 9 |
| Obr. 3-4 Dvouvrstvý perceptron [18] | 9 |
| Obr. 3-5 Lineárně oddělitelná data, nejtučnější přímka znázorňuje dělicí přímku pro ideální rozdělení objektů ze dvou skupin [21]..... | 10 |
| Obr. 3-6 Data rozdělená pomocí různých forem SVM [23] | 11 |
| Obr. 4-1 Ukázka dat naměřených pomocí akcelerometru | 13 |
| Obr. 4-2 Tepová frekvence naměřená pomocí PPG senzoru s naznačenými fázemi spánku | 14 |
| Obr. 4-3 Základní blokové schéma decimace (x_n je vstupní signál, $h(n)$ decimační filtr, M decimační faktor a y_n výstupní signál) | 14 |
| Obr. 4-4 Ukázka decimace signálu | 15 |
| Obr. 4-5 Ukázka úseku signálu interpolovaného pomocí splajnu a lineární metodou | 15 |
| Obr. 4-6 Srovnání úseku signálu naměřené tepové frekvence s Akima interpolací . | 16 |
| Obr. 5-1 Signal Vector Magnitude | 20 |
| Obr. 5-2 Signal Vector Magnitude v jednotlivých fázích spánku | 20 |
| Obr. 5-3 Rozptyl před transformací | 21 |
| Obr. 5-4 Histogramy původních hodnot směrodatné odchylky | 22 |
| Obr. 5-5 Vysvětlení funkce vybraných transformací, převzato z [33] | 23 |
| Obr. 5-6 Hodnoty směrodatné odchylky po odmocnění | 24 |
| Obr. 5-7 Hodnoty směrodatné odchylky po zlogaritmování | 24 |
| Obr. 5-8 Krabicové grafy rozptylu po odstranění odlehlých hodnot | 25 |
| Obr. 5-9 Boxplot VK TF ve skupinách Wake a Sleep..... | 26 |
| Obr. 5-10 Boxplot IQR akcelerometrických dat ve skupinách Wake a Sleep..... | 27 |
| Obr. 5-11 Boxplot VK TF ve skupinách Wake, REM a NREM | 28 |

| | |
|---|----|
| Obr. 5-12 Boxplot IQR akcelerometrických dat ve skupinách Wake, REM a NREM | 28 |
| Obr. 6-1 Ukázka matice záměn..... | 31 |
| Obr. 6-2 Model kritériální funkce v závislosti na hyperparametrech klasifikátoru.. | 33 |
| Obr. 6-3 Průběh minimalizace kritériální funkce | 33 |
| Obr. 6-4 Ukázka funkce parametru gama | 34 |
| Obr. 6-5 Průběh minimalizace kritériální funkce | 36 |
| Obr. 6-6 Matice záměn pro tři kategorie..... | 37 |
| Obr. 7-1 Srovnání parametru TST vypočítaného z dat hodnocených expertem a výstupu modelu | 41 |
| Obr. 7-2 Srovnání parametru TWT vypočítaného z dat hodnocených expertem a výstupu modelu..... | 42 |
| Obr. 7-3 Srovnání parametru WASO vypočítaného z dat hodnocených expertem a výstupu modelu..... | 43 |
| Obr. 7-4 Srovnání parametru SE vypočítaného z dat hodnocených expertem a výstupu modelu | 43 |
| Obr. 7-5 Hypnogram porovnávající výstupy experta a modelu (0 – Wake, 1 – Sleep) | 44 |
| Obr. 7-6 Srovnání parametru TST vypočítaného z dat hodnocených expertem a výstupu modelu | 45 |
| Obr. 7-7 Srovnání parametru TWT vypočítaného z dat hodnocených expertem a výstupu modelu..... | 45 |
| Obr. 7-8 Srovnání parametru WASO vypočítaného z dat hodnocených expertem a výstupu modelu..... | 46 |
| Obr. 7-9 Srovnání parametru SE vypočítaného z dat hodnocených expertem a výstupu modelu..... | 46 |
| Obr. 7-10 Srovnání procenta REM spánku vypočítaného z dat hodnocených expertem a výstupu modelu | 47 |
| Obr. 7-11 Hypnogram porovnávající výstupy experta a modelu, (0 – Wake, 1 – NREM, 2 – REM)..... | 48 |
| Obr. 7-12 Graf TF a pohybu na stejném úseku jako předchozí hypnogram..... | 48 |

| | |
|---|----|
| Obr. 7-13 Srovnání parametru TST vypočítaného z dat hodnocených expertem a výstupu modelu..... | 49 |
| Obr. 7-14 Srovnání parametru TWT vypočítaného z dat hodnocených expertem a výstupu modelu..... | 50 |
| Obr. 7-15 Srovnání parametru WASO vypočítaného z dat hodnocených expertem a výstupu modelu..... | 50 |
| Obr. 7-16 Srovnání parametru SE vypočítaného z dat hodnocených expertem a výstupu modelu..... | 51 |
| Obr. 7-17 Srovnání zastoupení REM spánku vypočítaného z dat hodnocených expertem a výstupu modelu | 51 |

Seznam tabulek

| | |
|---|----|
| Tabulka 5-1 Parametry vybrané na základě statistického testování | 29 |
| Tabulka 6-1 Přehled výsledků jednotlivých metod na testovací množině..... | 34 |
| Tabulka 6-2 Ukázka matice záměn: trénovací data | 35 |
| Tabulka 6-3 Ukázka matice záměn: testovací data..... | 35 |
| Tabulka 6-4 Přehled průměrných výsledků na testovacích a trénovacích datech | 35 |
| Tabulka 6-5 Přehled průměrných výsledků na testovacích a trénovacích datech, šířka pásma = 10, gama = 1,35 | 37 |
| Tabulka 6-6 Ukázka matice záměn: Trénovací data..... | 38 |
| Tabulka 6-7 Ukázka matice záměn: Testovací data | 38 |
| Tabulka 6-8 Matice záměn resubstituční metody | 39 |
| Tabulka 6-9 Přehled výsledků | 39 |
| Tabulka 6-10 Srovnání výsledků s literaturou | 40 |

ÚVOD

Zdravý spánek umožňuje regeneraci každé buňky lidského těla a je tedy nezbytnou součástí života – spánkem trávíme až jeho jednu třetinu. Jeho kvalitu ovlivňuje mnoho aspektů, z nejdůležitějších např. věk, délka hlubokého spánku, počet spánkových cyklů či spánkové poruchy. Standardem pro hodnocení kvality spánku a diagnostiku spánkových poruch je polysomnografie. Toto měření musí být podstoupeno ve specializované spánkové laboratoři. Právě kvůli počtu senzorů, které má pacient na sobě, či kvůli cizímu prostředí, mohou být výsledky zkresleny diskomfortem pacienta. Alternativou může být neustále se rozvíjející nositelná elektronika, která je lákavým řešením problému ambulantního vyšetřování spánku. Její používání je jednodušší, pohodlnější, levnější a je schopna měřit několik biologických signálů najednou. Prozatím však kvůli nižší senzitivitě a specifitě ve srovnání s PSG není v praxi využívána (více v kapitole 2.3).

Velkým trendem v oblasti vyhodnocování dat z nositelné elektroniky jsou metody strojového učení, a to převážně algoritmy učení s učitelem (např. neuronové sítě, metoda podpůrných vektorů, aj.). Tato práce se bude zabývat právě automatickou klasifikací bdění a spánku, popř. klasifikací REM a NREM spánku pomocí metody podpůrných vektorů, která patří mezi ty jednodušší, avšak dosahuje velmi dobrých výsledků. Data, která budou vyhodnocována, byla naměřena pomocí chytrých hodinek Apple Watch a obsahují záznam z akcelerometru a tepovou frekvenci.

1. FYZIOLOGIE SPÁNKU

Spánek je přirozený fyziologický proces, který se vyskytuje u všech vyšších obratlovců. Lze ho charakterizovat jako stav klidu, motorické inaktivity a relaxace.

Potřeba spánku každého člověka je vysoce individuální. Zdravý člověk spí v průměru 6-8 hodin denně, což může tvořit až 1/3 života. Důležitou roli v délce a kvalitě spánku hraje věk, jelikož potřeba i složení spánku se během života mění. Se zvyšujícím se věkem potřeba spánku i jeho kvalita klesá. Kvalita spánku se odvíjí především od délky hlubokého spánku a počtu spánkových cyklů. [1]

1.1 Spánkové fáze a jejich projevy v biologických signálech

Spánek je cyklický proces, během kterého se střídají různé úrovně hloubky spánku. Jeden spánkový cyklus zahrnuje periodu non-REM spánku a periodu REM spánku. Během spánku se vystřídá 4-5 spánkových cyklů. Jeden cyklus trvá cca 90-100 minut. K ránu se non-REM fáze zkracuje a spánek ztrácí svou hloubku, proto jsou spánkové cykly velmi variabilní.

Non-REM spánek se často označuje jako klidový. Jeho základní charakteristikou je pomalá EEG aktivita, kterou můžeme v záznamu rozpoznat jako vlny delta či théta. Non-REM spánek má čtyři fáze:

- NREM1 – Lehký, povrchní spánek, člověk je z něj lehce probuzen. V této fázi můžeme vidět pomalé oční pohyby a tzv. záškuby, které se zobrazují v záznamu elektrické aktivity očí (EOG). Na EEG můžeme pozorovat nástup pomalejších théta vln.
- NREM2 – Tato fáze může zabírat až 50 % celkového spánku. Dochází ke snížení svalového tonu, což se projevuje celkovým snížením úrovně signálu EMG. Na EEG vidíme delta a pomalé théta vlny, které mohou být přerušovány spánkovými vřeteny či K-komplexy.
- NREM3 – S přechodem do této fáze upadá člověk do hlubokého spánku a je velmi těžké jej probudit. Na EEG vidíme spánková vřetena a vlny delta.
- NREM4 – Tato fáze je hlubší NREM3. Funkce této fáze je pravděpodobně upevňování informací a vzpomínek.

Při přechodu z bdění do non-REM spánku můžeme na EEG vidět fázi usínání (NREM1) a jsou pro něj typické právě pomalé vlny théta. Změny pozorujeme také v jiných biologických signálech. Snižuje se krevní tlak a pozorujeme i snížení tepové či dechové frekvence. Když usneme, začnou převládat vlny delta. Mezi začátkem usínání a fází hlubokého spánku uběhne cca 30 minut. Probuzení je čím dál obtížnější. Postupně oslabují svaly, ztrácíme vědomí, snižuje se tepová frekvence, krevní tlak, což je výsledkem aktivity parasympatiku. Souběžně z EEG mizí spánková vřetena a K-komplexy. Z celkové doby spánku může NREM tvořit až zhruba 75 %.

Druhou částí spánkového cyklu je REM fáze neboli rapid eye movement. V této fázi na EEG převažují hlavně alfa a beta vlny, proto je tato fáze podobná bdění. Téměř všechny svaly jsou paralyzovány, aktivní zůstávají pouze ty obličejové. Tyto změny můžeme sledovat v EOG. Tepová frekvence i variabilita srdečního rytmu se zvyšuje a roste krevní tlak. Dechová frekvence se zrychluje a stává se nepravidelnou. Ve fázi REM převažuje aktivita sympatiku. [1]

1.2 Poruchy spánku

Poruchy spánku ovlivňují kvalitu spánku, jeho trvání i funkčnost člověka během dne. Tyto poruchy mohou přispět k dalším zdravotním problémům a některé mohou poukazovat i na psychické problémy.

Nejčastějšími spánkovými poruchami jsou insomnie, narkolepsie, parasomnie a nadměrná spavost. Ve spánku se projevuje také spánková apnoe.

Nespavost je definována jako přetrvávající potíže s usínáním, nepřetržitým spánkem a jeho kvalitou.

Narkolepsie je poruchou spánku definovanou jako nadměrnou ospalostí, mozek totiž není schopný regulovat cyklus spánku a bdění. Dalšími projevy mohou být i spánková paralýza, halucinace a kataplexie.

Spánková apnoe je porucha, při které se ve spánku opakovaně zastavuje dech pacienta. Tyto výpadky dechu ovlivňují kvalitu spánku a ovlivňují přísun kyslíku do těla, což může vést k vážným zdravotním následkům.

Parasomnie je termín pro neobvyklé chování, které lidé zažívají během spánku kvůli dysfunkci mozku. Jde o nežádoucí chování, pohyby, emoce apod. [2]

2. METODY MONITOROVÁNÍ SPÁNKU

2.1 Dotazníky

Pro diagnostiku, sledování reakce na léčbu či pro klinický výzkum lze použít mnoho typů dotazníků. Můžou být použity k predikování závažnosti poruch spánku. Většinou v takových dotaznících hodnotíme čas potřebný k zahájení spánku, kvalitu spánku, počet nočních probuzení a ospalost během dne. Za zmínku stojí např. Pittsburský index kvality spánku, který hodnotí kvalitu spánku v předchozím měsíci. Tento dotazník slouží k přiblížení závažnosti a povahy onemocnění. Některé dotazníky se soustředí přímo na konkrétní poruchu, nejznámější je Epworthská škála spavosti, která slouží k zachycení míry denní spavosti. Dále existují dotazníky (Hoffstein, Douglas, aj.), které se používají k detekci poruch dýchání, které souvisejí se spánkem. K hodnocení spánku a bdění se používají také dotazníky, které hodnotí spánkový cyklus. [2][3]

Nevýhodou těchto dotazníků je značná subjektivita. Pro objektivní posouzení kvality spánku slouží metody založené na analýze biologických signálů.

2.2 Polysomnografie

Zlatým standardem pro měření spánku je polysomnografie. Provádí se ve specializované laboratoři za přítomnosti odborného pracovníka. Výsledkem je polysomnogram. Při PSG je měřeno hned několik parametrů – elektroenceelografie (EEG), elektrokardiografie (EKG), elektromyografie (EMG), elektrookulografie (EOG), dechová aktivita, okysličení krve, poloha těla, esofageální tlak, tělesná teplota a krevní tlak. Zároveň je pořízen audiovizuální záznam k identifikaci abnormálních pohybů pacienta např. při spánkové parasomnii.


Klasifikace spánkových fází je založena převážně na typech vln v EEG, EMG (svaly brady) a EOG (horizontální a vertikální pohyby očních bulbů).

Nejdůležitější měřená data jsou [5]:

- celkový čas spánku, celkový čas vzhůru, celkový čas záznamu;
- efektivita spánku (celkový čas spánku vůči celkovému času záznamu);
- zpoždění začátku spánku, zpoždění první REM fáze a ostatních spánkových fází;
- délka (v minutách) a podíl jednotlivých fází spánku;
- frekvence apnoe a hypopnoe;
- saturace oxyhemoglobinu;
- celkový počet a periodicitu pohybu dolních končetin za hodinu spánku;
- srdeční rytmus a frekvence;
- probuzení pro počátku spánku.

Parametry jsou analyzovány každých 20 nebo 30 sekund, čemuž říkáme jedna spánková epocha. Délky epoch jsou stanoveny mezinárodními normami.

Rozložení a podíl spánkových fází můžeme znázornit hypnogramem (Obr. 2-1).



Obr. 2-1 Hypnogram [4]

Většina PSG systémů je v dnešní době digitální a jejich software tyto parametry analyzuje automaticky, ale musí být zkontrolovány i lidským expertem.

I když se PSG může jevit jako metoda s největší přesností, kvůli počtu senzorů, které má pacient na sobě, či cizím prostředím, mohou být výsledky zkresleny jeho nepohodlím. Také je metoda omezena na hodnocení spánku většinou pouze z jedné noci.

2.3 Aktigrafie


Aktigrafie je metoda pro hodnocení spánkového cyklu dle motorické aktivity. K měření se používá akcelerometr, který se nosí většinou na zápěstí nedominantní paže a snímá zrychlení ve všech osách (3D). Měří počet událostí, kdy celkové zrychlení překročí přednastavený práh pro časovou epochu (Obr. 2-2).

Aktigrafie pacientovi umožňuje pokračovat v běžném životě a rutinách. Velkou výhodou je, že jsou data zaznamenávána v jeho přirozeném prostředí. Získáváme informace o parametrech jako je celkový čas spánku, celkový čas vzhůru, počet probuzení, zpoždění začátku spánku a denní ospalost. Používá se k hodnocení nespavosti, poruch spánku, nadměrné ospalosti či syndromu neklidných nohou. Může se také použít k hodnocení léčby těchto poruch.

Při zachování pohyblivosti pacienta může být aktigrafie spolehlivou alternativou k PSG [5]. Její používání je jednodušší, dostupnější, pohodlnější a levnější. Může měřit několik biosignálů najednou a umožňuje nám získat informace o cirkadiálním rytmu, kdy je třeba několikadenní monitorování. Také umožňuje provést měření na pacientech, kteří se z nějakého důvodu nechtějí nebo nemohou podrobit klasickému PSG vyšetření.

Na druhou stranu určité parametry spánku a bdění měřené pomocí aktigrafie nejsou tolik spolehlivé. V porovnání s PSG aktigrafie nadhodnocuje délku spánku, a tím zkracuje dobu bdění, což je způsobeno tím, že obě metody určují začátek spánku jinými způsoby [6]. V aktigrafickém záznamu často znamená nehybnost pacienta začátek spánku. Na záznamu můžeme najít také tzv. záškuby, které se mohou vyskytovat např. u lidí s nepravidelným spánkovým cyklem a mohou ovlivňovat algoritmem určený počátek spánku. U PSG se spánkoví experti řídí spíše elektrickou aktivitou mozku a dalšími

signály. Změna v elektrické aktivitě mozku může však nastat až po nějaké době nehybnosti pacienta. Rozdíly v těchto parametrech nacházíme zejména u osob, které se v noci často probouzí a u těch, jejichž nespavost je spojena s psychiatrickým onemocněním [7].



Obr. 2-2 Data nasnímaná pomocí aktigrafu [8]

Současná generace nositelné elektroniky, která slouží k měření spánku používá multisenzorový sběr dat, nejčastěji z MEMS akcelerometru a fotopletysmografie (PPG). MEMS akcelerometry jsou senzory používané v mobilech a nositelné elektronice k měření pohybu a jsou v rámci možností spolehlivé pro měření fyzické aktivity a výdeje energie. V posledních letech jde technologie používající MEMS akcelerometry velmi dopředu a umožňuje zvýšit paměť, výdrž baterie, výkon se zvyšuje a cena snižuje.

Nositelná elektronika umožňuje také např. měření tepové frekvence pomocí pletysmografie (PPG). PPG je optická metoda, která měří změnu objemu krve a na jeho základě nám poskytuje informace o činnosti srdce. Tuto metodu využívají k měření tepové frekvence některé mobilní aplikace nebo např. Apple Watch. [5]

V klidu se tepová frekvence u zdravého dospělého člověka pohybuje mezi 60 a 90 tepy za minutu. Během spánku jsou srdeční i dýchací frekvence zpomaleny, aby se přizpůsobily sníženým metabolickým potřebám těla. V důsledku toho tepová frekvence klesá při přechodu do lehkého a poté do hlubokého spánku. Během REM spánku se tepová frekvence opět zvyšuje a vykazuje i vyšší variabilitu. [9]


Kvůli výsledkům v různých výzkumech zatím nemůžeme hodnocení kvality spánku pomocí nositelné elektroniky označit za metodu, který by byla spolehlivou náhradou PSG. V jedné studii při hodnocení kvality spánku pomocí hodinek Fitbit nabývalo rozlišení spánkových epoch senzitivity rozmezí 87 a 99 %. Specificita však byla značně nižší, pohybovala se v rozmezí 10-52 %. Při testování relativní novinky na trhu ŌURA prstenu, který měří kromě tepové frekvence a pohybu i dechovou frekvenci a tělesnou teplotu, bylo dosaženo až 96% senzitivity v detekci spánku, dále 65% senzitivity při detekci NREM 1 fáze, 51 % při detekci NREM 2 + NREM 3 fáze a 61 % při detekci REM fáze. Specificita detekce bdění dosáhla 48 %. [10] [11]

3. AUTOMATICKÉ HODNOCENÍ SPÁNKOVÝCH DAT

Automatické hodnocení spánkových fází prozatím zůstává náročným úkolem prováděným převážně odborníky. Proces manuálního hodnocení spočívá v kontrole EEG záznamů, což je jak časově náročné, tak i náchylné k lidské chybě. Manuální kontrola dat sice stále zůstává zlatým standardem, nedávné pokroky v algoritmech strojového učení však umožňují vývoj automatického hodnocení spánkových dat [12]. Nejčastěji využívaným metodám je věnována tato kapitola.

3.1 Metoda k-středů

Metoda k-středů (k-means) patří mezi metody shlukování. Jedná se o iterativní metodu, která rozděluje dataset do k shluků, které se nepřekrývají a jejich počet je předem znám. Každý objekt může patřit pouze do jednoho shluku. Na počátku algoritmu se zvolí počet centroidů (stejný jako počet shluků) a jejich souřadnice (většinou voleny náhodně). Pokud budeme mít např. $k = 2$, tedy dva centroidy, algoritmus se k nim bude snažit zařadit objekty tak, aby jednotlivé vzdálenosti objektů byly v rámci shluku co nejmenší, ale zároveň byly co nejdál od shluku druhého. K vypočtení vzdálenosti mezi shluky se využívá např. Euklidovské či Manhattanské vzdálenosti. Po přiřazení objektů k centroidům dojde k přepočítání souřadnic centroidu tak, aby byl středem shluku. Iterace se opakují, dokud dochází k posunu centroidů, nebo dokud nedosáhneme přijatelné odchylky. [13] Postup je znázorněn na obrázku 3-1.



Obr. 3-1 Znázornění průběhu algoritmu k-středů [14]

Po rozdělení dat do shluků je nutno implementovat navíc i algoritmus, který vyhodnotí, jakou skupinu dané shluky reprezentují.

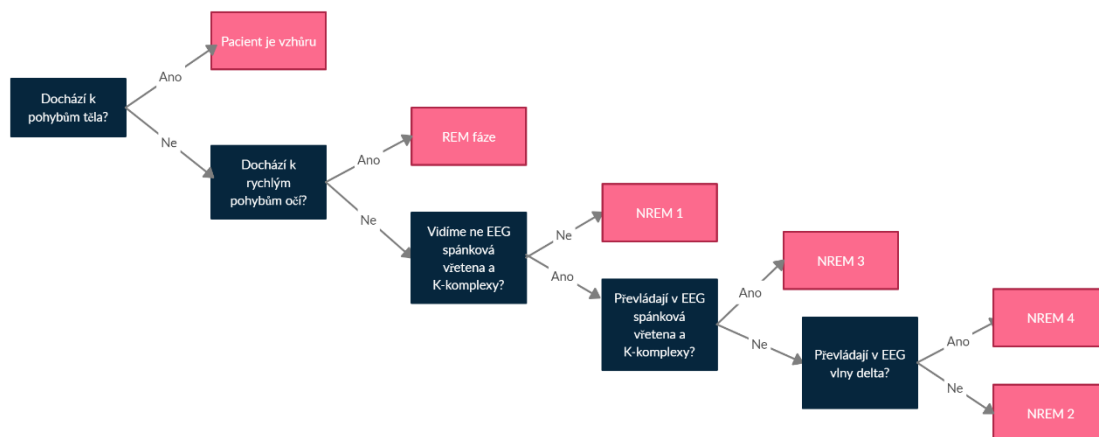
Tato metoda je vysoce závislá na počátečních souřadnicích centroidů a zvolené metrice vzdáleností. Pokud objekty netvoří přirozeně odlišné shluky, může být také neefektivní. Taky je velmi citlivá na odlehlé hodnoty, tudíž se někdy používá přímo k jejich detekci.

V práci *Automatic Detection of Sleep Stages Using the EEG* [15], kde bylo shlukování provedeno za základě Hjorthových parametrů, relativního výkonu v pásmu a parametrů harmonických složek (střední frekvence, šířka pásma), bylo dokázáno, že shlukování je schopno odlišit určité fáze jen z EEG. Algoritmus byl schopný velmi dobře odlišit skupinu Wake od NREM fází. Naopak shluky reprezentující fáze NREM 2 a NREM 3 se značně překrývaly. Pro lepší rozlišení autoři navrhli zahrnutí analýzy EKG či EOG.

3.2 Náhodný les

Základním prvkem náhodného lesa je rozhodovací strom, který klasifikuje data na základě otázek. Každá z otázek tvoří uzel a každý uzel je napojen na dceřiný uzel, který znázorňuje odpověď na otázku (větev). Otázky tvoří hierarchickou strukturu, která je kódována jako strom. Objekt je klasifikován od nejvrchnějšího uzlu (kořenu) dokud nedosáhne posledního uzlu, kde dojde k predikci, do jaké kategorie daný objekt patří (Obr. 3-2).

I když může být rozhodovací strom sám o sobě dobrý klasifikátor, vyšší přesnosti dosáhneme jejich kombinací, která se nazývá náhodný les.

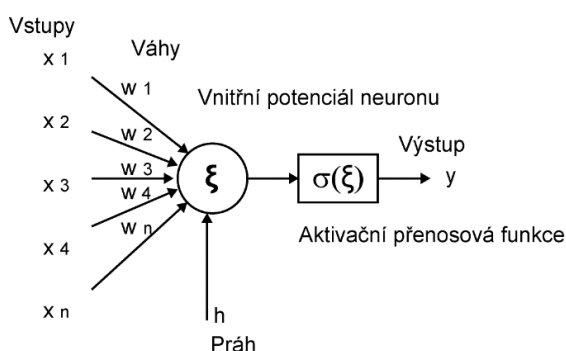


Obr. 3-2 Znázornění principu detekce spánkových fází s využitím rozhodovacího stromu

V článku *A new fully automated random-forest algorithm for sleep staging* [16] bylo využito dat z EEG a EOG a extrahováno mnoho příznaků, jako např. medián, rozptyl, variační rozpětí a Hjorthovy parametry v časové oblasti a příznaky jako např. výkon, maximální amplituda, frekvence, aj. Model byl trénován na datech ohodnocených experty a poté testován. Při testování vykazoval průměrnou přesnost 92,6 %.


3.3 Neuronová síť

Základním prvkem neuronové sítě je jeden neuron (perceptron), který je matematickým modelem biologického neuronu (Obr. 3-3). Neuron má několik částí. Vstupy x přivádí do těla neuronu dráhy (synapse). Každá dráha má určitou váhu w , kterou nastavujeme důležitost daného parametru (příznaku). V těle neuronu jsou váhované vstupy sečteny a je od nich odečten práh ξ . Pokud je výsledek kladný, tedy práh je překročen, neuron je aktivní a schopen posílat informaci dále. Tato hodnota pak vstupuje do aktivační funkce $\sigma(\xi)$, která transformuje hodnotu na výstup y . Aktivační funkce normalizuje hodnoty. Mezi nejpoužívanější patří např. funkce skoková nebo sigmoidální.



Obr. 3-3 Model neuronu [17]

Jednotlivé neurony jsou uspořádány do vrstev (Obr. 3-4). První vrstva je ta vstupní, pak následují skryté vrstvy a na konci se nachází vrstva výstupní. Neuron z předchozí vrstvy je většinou propojen se všemi neurony vrstvy následující.



Obr. 3-4 Dvouvrstvý perceptron [18]

Neuronovou síť můžeme optimalizovat učním, a to jak s učitelem, tak bez učitele. Učení bez učitele pracuje na principu shlukování. Algoritmus třídí vstupní data do shluků, jejichž počet bývá většinou předem dán. Tato metoda je základem pro tzv. samoorganizující se mapy. [19]


Učení s učitelem probíhá v tzv. epochách a je třeba předem znát vstupní i výstupní data. Váhy jsou nastaveny na určité hodnoty (často náhodné) a výstup neuronu je porovnán s požadovaným výstupem. Pokud se výstup na neuron a požadovaný výstup neshodují, musíme upravit váhy a model tzv. naučit. Tento postup je opakován, dokud se výstupy nebudou shodovat nebo dokud nedosáhneme maximálního počtu epoch učení.

Neuronové sítě dosahují v klasifikaci spánkových fází velmi dobrých výsledků. Přesnosti v některých člancích dosahují i hranice 90 %. Např. v článku *A convolutional neural network for sleep stage scoring from raw single-channel EEG* [20], kde se autoři snaží pomocí konvoluční neuronové sítě klasifikovat fáze REM, NREM1, NREM2, NREM 3 a bdění pouze z jednokanálového EEG, dosahuje přesnost algoritmu 87 %.

3.4 Support Vector Machines

Metodu podpůrných vektorů (angl. support vector machines, SVM) je vhodná jak pro data, které můžeme rozdělit lineárně, tak i pro lineárně neseparabilní data.

Při práci s daty, které můžeme rozdělit lineárně, hledáme přímku. Kolem přímky se nachází tzv. toleranční pásmo. Optimálně bychom měli najít přímku, která má co nejširší toleranční pásmo a zároveň se v něm nachází co nejmenší počet dat z trénovací množiny (Obr. 3-5). Pokud bude toleranční pásmo příliš úzké, dojde k přeučení modelu a bude špatně klasifikovat nová data. Bodům, které leží na hranici tolerančního pásma říkáme podpůrné vektory. Pokud by se tyto body jen nepatrně posunuly, posunula by se i hranice tolerančního pásma. Pokud pozměníme ostatní body, vliv na šířku pásma to bude mít jen v tom případě, že je posuneme blíže ke druhé třídě. V tomto případě by se posunutý bod stal novým podpůrným vektorem. [21]

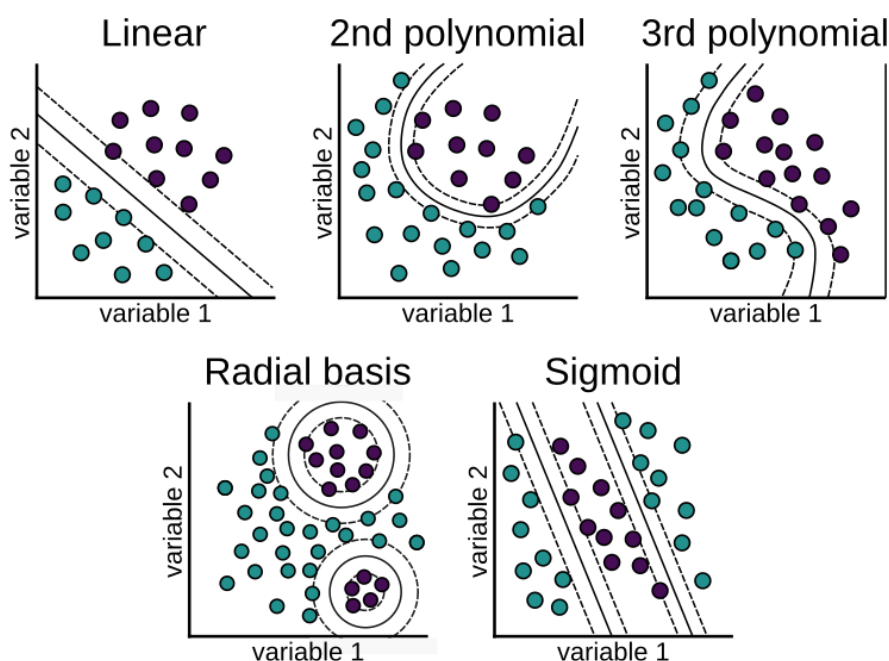


Obr. 3-5 Lineárně oddělitelná data, nejtučnější přímka znázorňuje dělicí přímku pro ideální rozdělení objektů ze dvou skupin [21]

Pokud jsou data lineárně neseparabilní, je na řadě transformace dat do vyšších dimenzí, kde už jsme schopni je lineárně oddělit. Pokud máme dvě kategorie dat ve 2D prostoru, které jdou oddělit nejlépe např. kružnicí, můžeme je transformovat do vyšší dimenze, kde už je budeme moci oddělit lineárně (nadrovina). Můžeme např. místo původního počtu p proměnných použít jejich kvadratické nebo kubické formy. Přidáním

proměnných se algoritmus nijak zásadně nezatíží a jeho náročnost se bude zvyšovat jen minimálně.

Nelineární verze SVM, kdy při transformaci do vyšší dimenze nelze body lineárně oddělit, transformuje prostor pomocí jader (kernels) – např. polynomiální či radiální bázové jádro (Obr. 3-6). Obecně platí, že N dat je možno rozdělit v prostoru o $N-1$ nebo více dimenzích. Problémem může být, že v d rozměrném prostoru bude oddělovač definován rovnicí o d parametrech, tudíž může snadno docházet k přetrénování modelu [22].



Obr. 3-6 Data rozdělená pomocí různých forem SVM [23]

Metoda podpůrných vektorů byla zvolena i pro tuto bakalářskou práci, a to z důvodu, že patří mezi jednodušší metody strojového učení (není třeba u ní nastavovat větší množství parametrů na rozdíl od neuronových sítí) a zároveň dosahuje velmi dobrých výsledků. Např. ve článku *Automatic SLEEP staging: From young adults to elderly patients using multi-class support vector machine* [24], kdy autoři odlišují bdění a REM a NREM fázi z dat naměřených EEG a EOG, dosahuje celková přesnost hodnoty 91 %.

4. ANALÝZA REÁLNÝCH SPÁNKOVÝCH DAT

Veřejně dostupná databáze používaná v této bakalářské práci byla získávána v rámci studie na Michiganské univerzitě od června 2017 do března 2019 [6]. Konečná databáze obsahuje záznamy tepové frekvence a pohybu od 25 osob.

4.1 Protokol měření

Celkem se studie zúčastnilo 39 osob. Všichni podepsali informovaný souhlas a vyplnili dotazník, který měl za úkol zjistit, jestli participant netrpí některým z následujících: syndrom neklidných nohou, poruchy dýchání ovlivňující spánek, insomnie, parasomnie, hypersomnie, kardiovaskulární problémy (vrozené srdeční vady, chronické srdeční selhání, ischemickou chorobu srdce, infarkt myokardu, arytmie aj.), periferní cévní onemocnění, poruchy zraku bez možnosti korekce brýlemi či kontaktními čočkami a další vážné neurologické či psychické choroby. Dále byli vyloučeni participant, kteří pracují na více směn či participant, kteří v posledním měsíci cestovali přes více než dvě časová pásma. Pomocí Epworthské škály spavosti bylo posuzováno, zda participant netrpí nadměrnou denní spavostí (nesměli mít skóre vyšší než 10, což indikuje nadměrnou denní spavost).

Po schválení byly účastníkům propůjčeny chytré hodinky Apple Watch, které nosili na zápěstí nepřetržitě 7–14 dní. Až čtrnáctidenní sběr dat dopomohl k zjištění návyků účastníka, které byly poté využity k predikci cirkadiálního rytmu. Do mobilu byla účastníkům nainstalována aplikace, která obsahovala digitální spánkový deník a PVT (psychomotoric vigilance test), který má za úkol zjistit, jak rychle participant reagují na vizuální stimul. Podle výzkumů rychlost a správnost reakce koreluje se spánkovým deficitem či nedostatkem hlubokého spánku. V této práci však tato data využita nebyla.


Poslední noc propůjčení hodinek přespali účastníci ve spánkové laboratoři Univerzity v Michiganu v čas, kdy jsou zvyklí chodit spát a podrobili se PSG. Během vyšetření měli na sobě účastníci dále hodinky Apple Watch, odkud byla data ihned odesílána na server. PSG bylo provedeno za účasti spánkového technika dle Americké akademie spánkové medicíny (kromě oronasálního termistoru a senzoru nosního tlaku). Využito bylo EEG, EMG (svaly brady), EOG (pohyby očí), RIP (respirační indukční pletysmografie – pohyb hrudních a břišních svalů při dýchání), mikrofonu pro detekci chrápání, pulzní oxymetrie a dvou svodového EKG.

Elektrofyzilogické signály prvních osmi pacientů byly získány pomocí Vitaportu 3, zbytek pomocí Graef HD-PSG/EEG. Účastníci, u kterých PSG odhalila poruchu REM spánku (náhlé pohyby končetin a zvuky vydávané během REM fáze) nebo spánkovou apnoei, byli odstraněni z databáze (celkem 4). Čtyři další účastníci byli vyjmuti kvůli

nekompletním datům. Pokud se baterie Apple Watch vybila před koncem PSG vyšetření, data byla zkrácena pouze na užitečnou část a použita.

4.2 Popis naměřených dat


Během PSG byla z Apple Watch odesílána na server surová data z akcelerometru a tepová frekvence. Apple Watch používají tříosý MEMS akcelerometr, který měří zrychlení pohybu v osách x, y a z v jednotkách g a obsahuje také časovou osu v sekundách datovanou od 1. 1. 1970, která byla upravena tak, aby odpovídala záznamu PSG vyšetření (Obr. 4-1). Data z akcelerometru byla vzorkována frekvencí $f_{vz} = 50$ Hz. Z těchto dat byl jeden pacient vyřazen, a to z důvodu velmi zpožděného odesílání dat na server.



Obr. 4-1 Ukázka dat naměřených pomocí akcelerometru

Tepová frekvence byla měřena pomocí PPG na dorzální straně zápěstí (Obr. 4-2). Z obrázku je patrné, že v NREM fázi dojde ke stabilizaci tepové frekvence, zatímco při bdění a REM fázi můžeme vidět větší rozptyl hodnot. Tepová frekvence by proto mohla být vhodná pro odlišení NREM fáze.

V některých záznamech (celkem 3) chyběly úseky dat kvůli problémům se serverem. Důsledkem toho docházelo ke změření tepové frekvence a k odeslání několika hodnot ve stejném čase došlo až např. o 20 s později. Proto se tato data nedala se stoprocentní jistotou rozřadit do epoch a byla odstraněna.




Obr. 4-2 Tepová frekvence naměřená pomocí PPG senzoru s naznačenými fázemi spánku

4.3 Předzpracování dat


Pro určení příznaků, podle kterých budou klasifikovány jednotlivé spánkové fáze bylo nutné nejdříve rozdělit signály do epoch dlouhých 30 sekund a přiřadit jim fázi, do které spadají.

Každý signál *akcelerometru* byl dlouhý několik hodin, proto obsahoval mnoho vzorků, které bylo poté velmi časově náročné zpracovat pro statistickou analýzu. Proto bylo přistoupeno k decimaci signálu (Obr. 4-3), což je proces, který zkracuje délku signálu odstraněním některých vzorků. Signál je decimován faktorem M , což znamená, že smažeme každý M -tý vzorek signálu. Protože se několikanásobně sníží vzorkovací frekvence, může dojít k aliasingu. Z toho důvodu musí být použit antialiasingový filtr. K tomu se využívá filtr typu dolní propusti s mezní frekvencí rovné polovině výsledného vzorkovacího kmitočtu.




Obr. 4-3 Základní blokové schéma decimace (x_n je vstupní signál, $h(n)$ decimační filtr, M decimační faktor a y_n výstupní signál)

Po vykreslení signálu a aplikování různě velkých decimačních faktorů byl zvolen decimační faktor $M = 3$ z důvodu dobrého zachování všech potřebných impulsů a zároveň výrazného snížení výpočetní náročnosti algoritmu a dolní propust typu FIR kvůli jejímu jednoduššímu návrhu (Obr. 4-4).



Obr. 4-4 Ukázka decimace signálu


Tepová frekvence byla načtena a před jejím zpracováním interpolována, abychom znali hodnotu tepové frekvence pro každou sekundu naměřeného signálu, protože byla neekvidistantně vzorkována. Při aplikaci lineární interpolace docházelo k tomu, že až do prvního naměřeného vzorku vektor obsahoval NaN hodnoty. Ke stejnému docházelo při interpolaci pomocí nejbližše naměřené sousední hodnoty a dalšími podobnými metodami.



Obr. 4-5 Ukázka úseku signálu interpolovaného pomocí splajnu a lineární metodou

Jako metoda interpolace byla nakonec zvolena interpolace Akima, která byla porovnávána s interpolací pomocí splajnu, která také vykazovala velkou podobnost k původním datům. Obě stojí na principu kubické interpolace a v Matlabu využívají extrapolaci, tudíž byly schopné doplnit hodnoty od první sekundy záznamu. Interpolace Akima zachovává sklon původní křivky a na rozdíl od splajnu není náchylná ke zvlnění

ve stagnujících oblastech křivky, což ukazuje Obr. 4-6. Interpolace pomocí splajnu byla v závěru i více náchylná k tvoření falešných peaků, kdežto interpolace Akima se ukázala jako vhodnější pro rychlé změny.



Obr. 4-6 Srovnání úseku signálu naměřené tepové frekvence s Akima interpolací

Jelikož signály tepové frekvence i signály z akcelerometru byly vždy o něco delší než jím odpovídající anotace PSG, všechny signály byly zkráceny na stejnou délku.

Poté byla data rozdělena do epoch dlouhých 30 sekund a v každé epoše byly spočítány vybrané parametry (viz další kapitola).

PSG anotace obsahovala číselné informace o tom, do jaké fáze přísluší daná epocha, kdy 0 nám říkala, že pacient je vzhůru; čísla 1, 2 a 3 pak v jaké NREM fázi se pacient nacházel a číslo 5 ukazovalo na REM fázi. Tyto informace byly využity k posouzení diskriminačních schopností vybraných parametrů a dále i k trénování modelu. V PSG anotacích se však objevovala i číslíce -1, která indikovala problém v měření. Tyto epochy byly ze signálů odstraněny.

5. PŘÍZNAKY PRO DETEKCI SPÁNKOVÝCH FÁZÍ

Aritmetický průměr, kvadratický průměr a medián byly do příznaků zařazeny z toho důvodu, že by měly zachytit snížení tepové frekvence, ke kterému dochází při usínání. V REM fázi můžeme naopak sledovat zvýšení tepové frekvence. Rozptyl, směrodatná odchylka, variační koeficient a mezikvartilové rozpětí byly zvoleny z důvodu vyšší rozptýlenosti hodnot tepové frekvence v REM fázi, zatímco v NREM fázích můžeme vidět spíše konstantní TF. [25][26] [27]

Parametry šikmost, špičatost, 90. percentil, 75. percentil, 25. percentil, 10. percentil, energie signálu a SMA (signal magnitude area) byly do příznaků zařazeny z důvodu využití v několika publikacích, kde byly vybrány mezi příznaky pro trénování neuronové sítě a vykazovaly vylepšení její přesnosti o jednotky procent. [28][29].

5.1 Příznaky extrahované z tepové frekvence

Aritmetický průměr

Aritmetický průměr se počítá jako součet všech hodnot v intervalu vydělený jejich počtem (5-1). Všechny hodnoty mají ve výpočtu stejnou váhu. Pokud se v dané epoše vyskytují odlehlé hodnoty, průměr jimi může být výrazně ovlivněn. Bylo prokázáno, že v NREM fázích spánku dochází ke snížení průměrné tepové frekvence, naopak v REM fázi k jejímu zvýšení [27].

$$\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n) = \frac{1}{n} \sum_{i=1}^n X_i \quad (5-1)$$

kde n je počet vzorků signálu X_i v epoše.

Kvadratický průměr

Kvadratický průměr je veličina, která představuje druhou odmocninu aritmetického průměru z druhých mocnin daných hodnot. Je vždy nezáporný a větší nebo roven aritmetickému průměru. Vyšší hodnoty mají v kvadratickém průměru větší váhu, čehož by potenciálně mohlo být využito převážně v akcelerometrických datech.

$$X_{RMS} = \sqrt{\frac{1}{n}(X_1^2 + X_2^2 + \dots + X_n^2)} \quad (5-2)$$

kde n je počet vzorků signálu X_i v epoše.

Medián

Medián je hodnota, která dělí soubor hodnot na dvě poloviny, tudíž 50 % dat má vyšší hodnotu než medián a 50 % má nižší hodnotu než medián. Oproti průměru medián není ovlivňován extrémními hodnotami a stejně jako aritmetický průměr či kvadratický průměr by měl vykazovat vyšší hodnoty v REM fázi a při bdění.

$$Me(X) = X_{\frac{n+1}{2}}, \text{ pro } n \text{ liché} \quad (5-3)$$

$$Me(X) = \frac{X_{\frac{n}{2}} + X_{\frac{n}{2}+1}}{2}, \text{ pro } n \text{ sudé} \quad (5-4)$$

kde n je počet vzorků signálu X_i v epoše.

Rozptyl

Rozptyl ukazuje míru rozptýlení hodnot kolem střední hodnoty. V REM fázi můžeme sledovat vyšší variabilitu hodnot tepové frekvence, kdežto v NREM fázi je tepová frekvence téměř konstantní.

$$Var(X) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (5-5)$$

kde n je počet vzorků signálu X_i v epoše, \bar{X} značí aritmetický průměr v epoše.

Směrodatná odchylka

Směrodatná odchylka se rovná druhé odmocnině z rozptylu. Stejně jako rozptyl ukazuje míru rozptýlení hodnot okolo střední hodnoty.

$$\sigma = \sqrt{Var(X)} \quad (5-6)$$

kde $Var(X)$ značí rozptyl.

Mezikvartilové rozpětí

Mezikvartilové rozpětí ukazuje rozdíl mezi 75. kvantilem a 25. kvantilem, tedy mezi oblastí, kam spadá 75 % hodnot a oblastí, kam spadá nejnižších 25 % hodnot. Reprezentuje tedy oblast hodnot, kde se nachází 50 % všech hodnot a není ovlivněno odlehlými hodnotami.

$$IQR = X_{0.75} - X_{0.25} \quad (5-7)$$

kde $X_{0.75}$ vyjadřuje 75% kvantil a $X_{0.25}$ 25% kvantil.

75. percentil a 25. percentil byl taktéž zařazen mezi příznaky.

Variační koeficient

Variační koeficient se spočítá jako poměr směrodatné odchylky a aritmetického průměru a udává tedy rozptýlenost hodnot vzhledem k průměru.

$$k = \frac{\sigma}{\bar{X}} \quad (5-8)$$

kde σ značí směrodatnou odchylku a \bar{X} aritmetický průměr.

Variační rozpětí

Variační rozpětí je rozdíl mezi maximální a minimální hodnotou v souboru dat. Jeho hodnota může být značně ovlivněna odlehlými hodnotami.

$$R = X_{max} - X_{min} \quad (5-9)$$

kde X_{max} vyjadřuje nejvyšší hodnotu v dané epoše a X_{min} tu nejnižší.

Šikmost

Šikmost popisuje rozdělení souboru dat kolem střední hodnoty a říká nám, zda jsou data rozdělena symetricky či nikoliv. Kladná šikmost značí odlehlejší hodnoty směrem vpravo od střední hodnoty. V NREM fázích bychom měli tudíž vidět šikmost blížící se 0.

$$\gamma = \frac{\mu_3}{\sigma^3} \quad (5-10)$$

kde μ_3 je třetí centrální moment a σ směrodatná odchylka.

Špičatost

Špičatost nám říká, do jaké míry jsou hodnoty koncentrovány kolem střední hodnoty. Kladná špičatost značí, že většina hodnot je koncentrována kolem střední hodnoty.


$$\gamma = \frac{\mu_4}{\sigma^4} \quad (5-11)$$

kde μ_4 je čtvrtý centrální moment a σ směrodatná odchylka.

5.2 Příznaky extrahované z pohybu


Z původních vektorů x , y a z představujících zrychlení v jednotlivých osách byl vytvořen pouze jeden vektor, který vypovídá o změně pohybu v jakékoli ze tří os. Tento vektor se nazývá Signal Vector Magnitude (Obr. 5-1, Obr. 5-2). Pokud se pacient nepohybuje, jeho hodnota je 1 g. Pokud dochází k nějakému pohybu, jeho hodnota se vychýlí od hodnoty 1 g. Velikost vychýlení závisí jak na velikosti pohybu, tak i na jeho rychlosti, proto může být někdy využíván k rozpoznání denních aktivit, jako je např. chůze, běh či sezení. [30]

$$S(k) = \sqrt{x_k^2 + y_k^2 + z_k^2} \quad (5-12)$$



Obr. 5-1 Signal Vector Magnitude

Z dat o pohybu byly extrahovány téměř stejné příznaky, jako z dat o tepové frekvenci. Přidány byly energie, Signal Magnitude Area (SMA), 10. percentil a 90. percentil z důvodu dobrých diskriminačních výsledků v uvedené literatuře. [31]



Obr. 5-2 Signal Vector Magnitude v jednotlivých fázích spánku

SMA

Signal Magnitude Area je jeden z nejpoužívanějších parametrů využívaných k měření z akcelerometrických dat [31]:

$$SMA = \frac{1}{i} \left(\sum_{u=1}^i |x_u| + \sum_{u=1}^i |y_u| + \sum_{u=1}^i |z_u| \right) \quad (5-13)$$

kde i je počet vzorků signálu v epoše.

Energie signálu

Dalším parametrem je energie signálu, která bývá využívána pro rozlišení jednotlivých aktivit z akcelerometru. K výpočtu byl využit vektor SVM.


$$E = \frac{\sum_{i=1}^n FFT_{SVM}^2}{n} - \overline{SVM} \quad (5-14)$$

kde n je počet vzorků v epoše, FFT značí Fourierovu transformaci a \overline{SVM} značí průměr vektoru SVM v dané epoše. [32]

Dále byly pro pohyb spočítány parametry 10., 25., 75. a 90. percentil.


5.3 Transformace parametrů tepové frekvence

Z následných krabicových grafů, které byly vykresleny pro všechny vybrané příznaky, bylo patrné, že data vykazují asymetrické rozložení. Asymetrické rozložení se na krabicovém grafu projeví jako velké množství odlehklých hodnot (Obr. 5-3). Tímto byla poté způsobena i statisticky významná odlišnost mezi fázemi, proto byla data nelineárně transformována na nové hodnoty, aby se jejich rozložení přiblížilo k normálnímu.

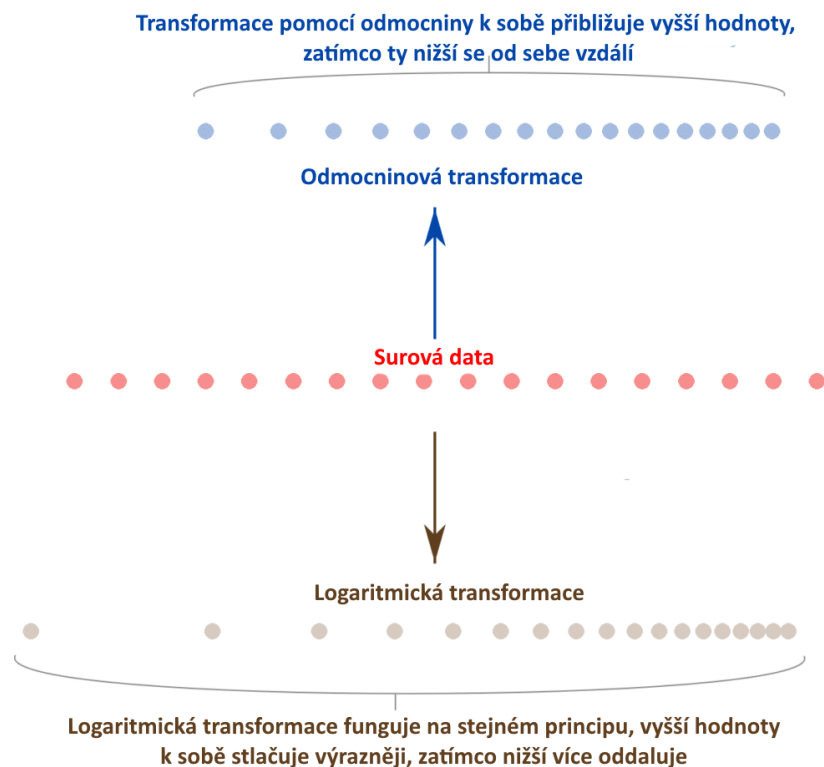


Obr. 5-3 Rozptyl před transformací

Pro všechny příznaky byly vykresleny histogramy, aby bylo zjištěno, pro které příznaky je vhodná transformace hodnot, popř. který její typ. Na datech byla testována logaritmická a odmocninová transformace. Logaritmická transformace je jednou z těch nejpoužívanějších a slouží právě k přiblížení k normálnímu rozdělení dat či přímo jejich normalizaci, stejně jako ta odmocninová. Odmocninová je pak vhodná pro data, které mají kladnou šikmost [33]. Na Obr. 5-4 je vykresleno původní rozložení směrodatné odchylky pro 27 pacientů.




Obr. 5-4 Histogramy původních hodnot směrodatné odchylky



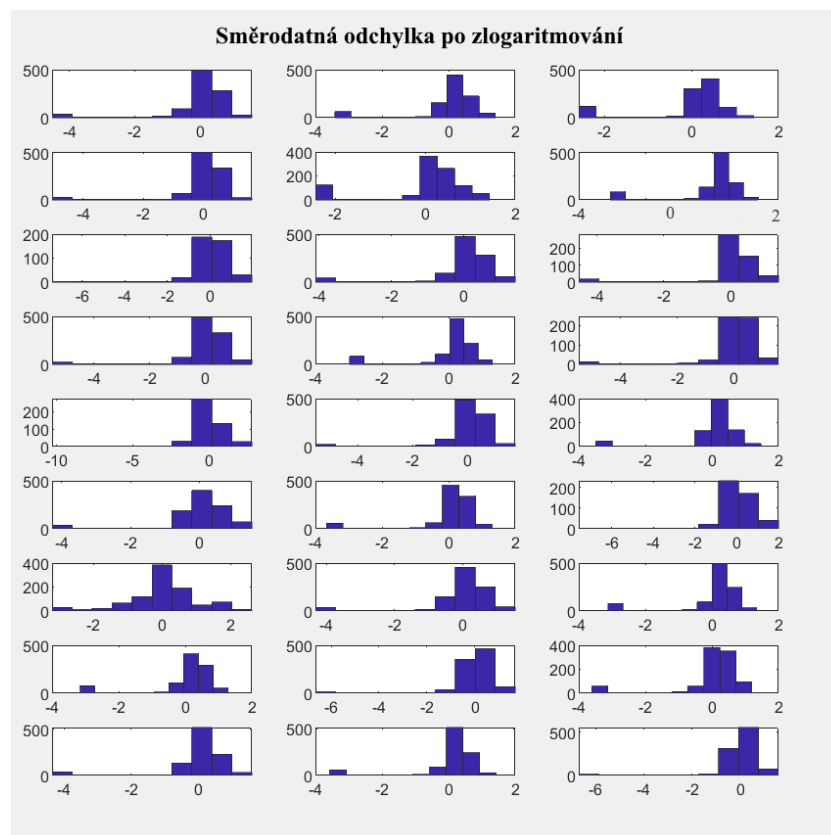
Obr. 5-5 Vysvětlení funkce vybraných transformací, převzato z [33]

Nejprve byla na všechna data aplikována logaritmická transformace. Jelikož se v datech vyskytovaly i nuly, všechna data byla posunuta o 0.001, aby byly nulové hodnoty zpracovány transformací. Tímto způsobem je zavedena systematická chyba, která by neměla ovlivňovat následnou klasifikaci dat. Stejně tak byla na data aplikována odmocninová transformace. Poté byly srovnány histogramy příznaků vzniklé jejich transformací a pro každý příznak byla vybrána vhodná transformace. Ve výsledku byly odmocněny příznaky IQR, variační rozpětí, variační koeficient, kvadratický průměr, směrodatná odchylka a 25. percentil. Zbytek příznaků byl zlogaritmován.

Jako ukázkou jsem vybrala směrodatnou odchylku, jejíž data jsou jedny z těch, které vykazovaly kladnou šikmost. Na histogramech (Obr. 5-6), které byly vykresleny z odmocněných dat je vidět, že rozložení spousty z nich se blíží normálnímu, kdežto logaritmická transformace se ukázala jako nevhodná (Obr. 5-7).



Obr. 5-6 Hodnoty směrodatné odchylky po odmocnění



Obr. 5-7 Hodnoty směrodatné odchylky pro zlogaritmování


Standardizace parametrů

Pokud sledujeme několik parametrů, které mají různou škálu hodnot, pro efektivnější učení klasifikačního modelu je vhodné převést jejich hodnoty na škálu standardizovanou. Pro tuto práci byla vybrána transformace pomocí z-skóre (5-15). Jedná se o lineární transformaci, což znamená, že škálu sice posunuje, ale nemění vzdálenosti mezi hodnotami, pouze měřítko.

$$z = \frac{X - \bar{X}}{\sigma} \quad (5-15)$$

kde \bar{X} značí aritmetický průměr a σ vyjadřuje směrodatnou odchylku.

Po normalizaci byly v signálech tepové frekvence odstraněny (a následně nahrazeny) odlehlé hodnoty, které mohly vzniknout jak při interpolaci, tak i při problémech s měřením. Většina signálů tepové frekvence vykazovala vysoké peaky, které u některých pacientů dosahovaly až hodnot v rozmezí 140-160 tepů/min. Jako odlehlá hodnota byla označena taková hodnota, která byla vzdálena od horního či dolního kvartilu o více než 1,5násobek mezikvartilového rozpětí. Pokud hodnota byla vyšší než horní kvartil, byla nahrazena tou nejvyšší, která spadala do určeného rozmezí. Pokud byla nižší než dolní kvartil, byla nahrazena tou nejnižší, která spadala do zvoleného rozmezí. Na Obr. 5-8 lze vidět rozložení rozptylu po odstranění odlehlých hodnot.




Obr. 5-8 Křabicové grafy rozptylu po odstranění odlehlých hodnot

5.4 Statistická analýza parametrů

Statistická analýza proběhla v prostředí MATLAB. Nejdříve byl na data aplikován Kolmogorovův-Smirnovův test na hladině významnosti $\alpha = 0,05$ pro normální rozložení.


Podle očekávání test rozhodl, že žádný z příznaků nemá normální rozložení. Pro srovnání skupin Sleep (spánek) a Wake (bdění) byl zvolen Mann-Whitneyův neparametrický test. Tento test pracuje s pořadím hodnot. Obě skupiny dat jsou sloučeny do jedné a hodnotám je přiřazeno pořadí (od 1 do n). Pokud jsou dvě hodnoty stejné, je jim přiřazeno průměrné pořadí. Poté jsou opět vráceny do původních skupin. U obou skupin dat je poté pořadí sečteno a menší z nich je porovnáno s tabulkovou kritickou hodnotou testu. Hladina významnosti byla nastavena na $\alpha = 0,05$. Nulová hypotéza h_0 zněla tak, že vybrané parametry se ve spánku a bdění neliší. Pokud výsledná hodnota p pro daný parametr byla menší než hladina významnosti, nulová hypotéza byla zamítnuta a parametr vybrán jako ten, který se ve spánku a bdění liší.



Obr. 5-9 Boxplot VK TF ve skupinách Wake a Sleep

Statisticky významnou odlišnost v tepové frekvenci ukázaly všechny parametry. Pro trénování modelu bylo poté vyzkoušeno více jejich kombinací (viz Kap. 6). Pro ukázkou byl vybrán variační koeficient (Obr. 5-9) a mezikvartilové rozpětí (Obr. 5-10). Na Obr. 5-9 je vidět vyšší variabilita hodnot ve fázi Wake, zatímco ve spánku se variabilita snižuje. Tento parametr byl poté vybrán pro trénování modelu. Na Obr. 5-10 můžeme vidět větší rozpětí hodnot ve fázi Sleep, tento parametr však dostatečně neodlišoval obě skupiny, a proto nebyl vybrán pro trénování modelu.

Statistickou významnou odlišnost v datech z akcelerometru při rozdělení do dvou skupin vykazovaly příznaky minimum, maximum a 75. percentil.




Obr. 5-10 Boxplot IQR akcelerometrických dat ve skupinách Wake a Sleep

Pro zjištění statistické významnosti parametrů ve skupinách Wake, NREM a REM byl zvolen neparametrický Kruskalův-Wallisův test, který je rozšířením Mann-Whitneyova testu pro více než dva výběry. Data byla opět sloučena a jednotlivým hodnotám přiřazeno pořadí. Odsud pak může být vypočítána testová statistika Q Kruskalova-Wallisova testu (5-16). Pokud platí nulová hypotéza, tedy že se data v daných skupinách neliší, testová statistika nabývá chí-kvadrátu rozdělení pravděpodobnosti. Nulovou hypotézu zamítáme na hladině významnosti α , pokud testová statistika nabývá vysokých hodnot. Pokud je hodnota blízká číslu 1, parametry ve skupinách jsou podobné. [34]


$$Q = \frac{12}{N(N+1)} \sum_{i=1}^k \frac{T_i^2}{n_i} - 3(n+1) \quad (5-16)$$

kde k je počet tříd, T_i součet pořadí v i -té třídě, n_i počet pozorování a N počet pozorování v jednotlivých třídách.

V tepové frekvenci byly takto vybrány parametry průměr, maximum, 75. percentil, variační koeficient a variační rozpětí. V datech z akcelerometru byla tímto testem vybrána většina příznaků. Pro srovnání byly opět vybrány parametry variační koeficient (Obr. 5-11) a IQR (Obr. 5-12). Oba tyto parametry byly také později vybrány k trénování modelu, variační koeficient pro jeho schopnost odlišit spánek včetně REM fáze a IQR bylo jeden z mála parametrů, ve kterém se promítaly odlišnosti fází Wake a REM.



Obr. 5-11 Boxplot VK TF ve skupinách Wake, REM a NREM



Obr. 5-12 Boxplot IQR akcelerometrických dat ve skupinách Wake, REM a NREM

Výstup z Kruskal-Wallisova testu zněl tak, že výše uvedené parametry se v daných skupinách liší, ale neříká nám, jestli se liší ve všech testovaných skupinách či pouze v některých. Proto bylo provedeno post-hoc testování, kde byly proti sobě porovnávány jednotlivé dvojice, aby bylo zjištěno, v kterých konkrétních skupinách se parametry liší. Byl k tomu využit Tukeyův HSD test (Honest significant difference), který porovnává průměry jednotlivých skupin.

Data tepové frekvence se ve všech skupinách lišily ve čtyřech příznacích, a to byly medián, 25. percentil, špičatost a variační koeficient.

V případě akcelerometrický dat toto testování vyřadilo většinu příznaků. Statisticky odlišné ve všech třech skupinách od sebe byly příznaky průměr, směrodatná odchylka, IQR, minimum a maximum.

Tabulka 5-1 Parametry vybrané na základě statistického testování

| Typ signálu | Rozdělení | Vybrané parametry |
|-----------------------|---------------|---|
| Akcelerometrická data | Wake/Sleep | minimum, maximum, 75. percentil |
| | Wake/REM/NREM | průměr, směrodatná odchylka, IQR, minimum, maximum |
| Tepová frekvence | Wake/Sleep | rozptyl, směrodatná odchylka, variační koeficient, kvadratický průměr |
| | Wake/REM/NREM | medián, 25. percentil, špičatost, variační koeficient |

6. KLASIFIKACE SPÁNKOVÝCH EPOCH

Pro klasifikaci spánkových epoch byla zvolena metoda podpůrných vektorů (SVM). Jak už bylo uvedeno v Kap. 3, byla vybrána z důvodu její jednoduchosti (méně parametrů k nastavení než např. neuronová síť). I přes její jednoduchost umí dosahovat velmi dobrých výsledků při klasifikaci spánkových dat [24].

Jako vstupy do modelu SVM sloužily příznaky, které byly vybrány pomocí statistického testování. Vypočtené hodnoty byly rozděleny na trénovací data, která byla využita k trénování modelu, a na testovací, na kterých probíhalo ověřování úspěšnosti navrženého modelu. Trénování probíhalo vždy na cca 70 % dat a testování cca na 30 %, rozdělení nebylo přesné z toho důvodu, že byla snaha zanechat data od jednoho pacienta vždy buď v trénovací či testovací sadě. Trénování proběhlo ve třech cyklech, kdy na začátku byla data náhodně rozdělena do tří skupin a v každém cyklu byl model natrénován na dvou z daných skupin a na jedné testován. Takto se ve třech cyklech prostrídaly, aby nikdy model nikdy nebyl testován na datech, na kterých byl trénován. Tento postup se nazývá křížová validace. Rozdělení na tři skupiny se projevilo jako nejlepší vzhledem k rovnoměrnému učení jednotlivých sad dat a dostupnému (relativně limitovanému) počtu osob v databázi.

6.1 Binární klasifikace: Wake vs. Sleep

Při efektivním učení modelu je třeba, aby jednotlivé skupiny, které se snažíme klasifikovat, měly zhruba stejné zastoupení. Jelikož bylo zjištěno, že data, která byla naměřena ve spánku výrazně převažují, data z fáze bdění musela být doplněna. Jako první bylo zvažováno doplnění hodnot bdění z času před začátkem PSG vyšetření. Od toho však bylo ustoupeno z důvodu možného zatížení dat pohybovými artefakty. Další zvažovanou metodou byla replikace dat, která sice rozšíří data, ale modelu neposkytne žádné nové informace pro učení. Jeden z vyzkoušených způsobů srovnání množství dat v obou skupinách byla metoda, kdy na replikovaná data aplikujeme náhodný šum. Data byla nejdříve replikována a pak k nim byl přičten vektor, který obsahoval náhodně vygenerovaná čísla v rozmezí $\pm \text{STD}/3$. Tato metoda přispěla ke zlepšení výsledku klasifikace o několik jednotek procent. Jako poslední byla vyzkoušena aplikace cost matrix (tzv. matice ztrát), kterou nabízí přímo funkce *fitsvm*, která byla využita pro trénování modelu. Pomocí této matice můžeme skupině, která je méně zastoupená přiřadit větší váhu při výpočtu chyby při její chybné klasifikaci. I tento způsob vylepšil výsledky modelu.

Pro vyhodnocování úspěšnosti modelu byly zvoleny parametry, které jsou počítány z matice záměn. V matici záměn (Obr. 6-1) při klasifikaci dvou tříd budou čtyři pole. Na diagonále se nacházejí epochy, které byly zařazeny správně, a to správně pozitivní (TP) a správně negativní (TN). V pravém horním rohu najdeme epochy, které byly

označeny jako bdění, ale pacient spal, tzv. falešně negativní (FN). V levém dolním rohu jsou potom epochy, které byly označeny jako spánek, ale pacient byl vzhůru, tzv. falešně pozitivní (FP).

Z této matice jsou pak počítány vybrané parametry pro hodnocení modelu, a to senzitivita, specificita, pozitivní prediktivní hodnota (PPV), F1 skóre a celková přesnost.

| | | Skutečná kategorie | | |
|-----------------------|-------|--------------------|--------------------|----------|
| | | SLEEP | WAKE | |
| Predikovaná kategorie | SLEEP | Skutečně pozitivní | Falešně pozitivní | PPV |
| | WAKE | Falešně negativní | Skutečně negativní | NPV |
| | | Senzitivita | Specificita | Přesnost |

Obr. 6-1 Ukázka matice záměn

Senzitivita

Senzitivita vyjadřuje procento spánkových epoch označených správně jako spánek.

$$Se = \frac{TP}{TP + FN} \quad (6-1)$$

Specificita

Specificita nám říká, jaké procento z epoch označených jako bdění byl pacient skutečně vzhůru.

$$Sp = \frac{TN}{TN + FP} \quad (6-2)$$

Pozitivní prediktivní hodnota

Pozitivní prediktivní hodnota vypovídá o tom, jestli v epoše, která byla označena jako spánek, pacient skutečně spal.

$$PPV = \frac{TP}{TP + FP} \quad (6-3)$$

Negativní prediktivní hodnota

Negativní prediktivní hodnota nám udává, s jakou pravděpodobností byl pacient v epoše, která byla označena jako bdění skutečně vzhůru.

$$NPV = \frac{TN}{TN + FN} \quad (6-4)$$

Přesnost

Celková přesnost vyjadřuje procento správně zařazených epoch.

$$Acc = \frac{TP + TN}{TP + FN + FP + TN} \quad (6-5)$$

F1 skóre

F1 skóre počítá celkovou přesnost testování. Je počítáno ze senzitivity a PPV hodnoty a vyjadřuje jejich harmonický průměr.

$$F1 = 2 \frac{Senzitivita \cdot PPV}{Senzitivita + PPV} \quad (6-6)$$


Nastavení modelu

Nedříve byl navrhnut základní model, který měl defaultní nastavení a používal pouze lineární jádro, které využívá k rozdělení dat přímku. Do modelu byly přivedeny příznaky, které nebyly nijak upraveny výše uvedenými metodami. Tento model rozeznával bdění od spánku velmi špatně. Poté byla vyměněna lineární funkce za polynomiální jádro třetího řádu. Polynomiální jádro dosahovalo velmi podobných výsledků jako to lineární. Nakonec bylo do funkce aplikováno radiální bazové jádro, které by mělo dosahovat nejlepších výsledků, protože se velmi dobře přizpůsobuje datům (viz Kap 3.4). Na testovacích datech se jeho senzitivita pohybovala kolem 60 %, specificita poté až 92 %, nicméně PPV a F1 skóre nedosahovaly ani 30 %. Nízká hodnota F1 skóre byla způsobena tím, že počet spánkových epoch a epoch bdění nebyl vyrovnán. Model tak zařadil většinu spánkových epoch správně, ale stále měl problém zařadit epochy, kdy byl pacient vzhůru.


Jelikož dle výsledků statistických testů všechny příznaky odvozené z tepové frekvence jsou schopné odlišit fáze Wake a Sleep, bylo vyzkoušeno několik jejich kombinací. K vybraným parametrům pohybu byly postupně přidávány parametry, které měly nejnížší p hodnotu (nejvyšší odlišnost). Jako nejlepší se ukázala právě kombinace uvedená v Kap. 5. Kromě kombinací různých příznaků byla také vyzkoušena aplikace jak replikace dat s přidáním šumu, tak i cost matrix a poté opět jejich kombinace. Jako nejlepší nalezené řešení se ukázala právě jejich kombinace. Jelikož u každého pacienta se poměrově nacházel zhruba stejný počet epoch bdění ku počtu epoch spánku, u každého pacienta byly vybrány epochy, kdy je pacient vzhůru a byly dvakrát zreplikovány. K zreplikovaným datům byl přičten šum, který byl vygenerován v rozsahu $\pm \text{STD}/3$. Počet dat stále nebyl vyrovnán, proto byla do modelu ještě přidána cost matrix, která téměř dvojnásobně ($1,8\times$) přidala váhu pro výpočet chyby při chybné klasifikaci epochy bdění jako epochy spánku. Tato hodnota se odvíjela od počtu epoch v jednotlivých fázích.

Pokud tato hodnota byla vyšší, docházelo k přeučování modelu na datech ze skupiny Wake.


Posledním krokem bylo nastavení parametrů modelu, proto proběhla optimalizace hyperparametrů modelu, jejichž hodnoty jsou upravovány v rámci procesu učení. K tomu byla využita Bayesovská optimalizace, která funguje tak, že vytvoří pravděpodobnostní model kritériální funkce (Obr. 6-2), který je pak prohledáván akviziční funkcí. Tato funkce náhodně vybere vzorky, pomocí kterých poté vyhodnotí skutečnou kritériální funkci (Obr. 6-3) při snaze tuto funkci minimalizovat (minimalizace chyby). Takto je vyhledána optimální šířka tolerančního pásma a také parametr gama (Obr. 6-4), který souvisí s tím, jak dobře se bude jádro (či vektor) přizpůsobovat daným hodnotám. Přehled úspěšnosti metod, které byly využity při trénování modelu naleznete v Tabulce 6-1 (Tabulka 6-1). Tučně je vyznačen model, který byl použit.



Obr. 6-2 Model kritériální funkce v závislosti na hyperparametrech klasifikátoru



Obr. 6-3 Průběh minimalizace kritériální funkce



Obr. 6-4 Ukázka funkce parametru gama

Při kombinaci replikace dat s přidáním šumem a cost matrix a zvolení vhodných příznaků dosahovaly všechny počítané parametry (Se, Sp, Acc, F1 skóre, PPV, NPV) hranice 70 % na trénovacích datech. Na testovacích datech byly počítané parametry pouze o cca 2 % nižší. Vyhodnoceny byly také výsledky parametrů pro jednotlivé cykly (Tabulka 6-2, Tabulka 6-3). Následně byly hodnoty parametrů zprůměrovány, aby byl zjištěn celkový výsledek učení (Tabulka 6-4).

Tabulka 6-1 Přehled výsledků jednotlivých metod na testovací množině

| Augmentace dat | Jádro | Optimalizace | Se [%] | Sp [%] | PPV [%] | F1 skóre [%] |
|-------------------------------|--------------|-------------------|-------------|-------------|-------------|--------------|
| žádná | lineární | žádná | 74,2 | 84,0 | 25,4 | 37,8 |
| žádná | polynomiální | žádná | 73,0 | 84,3 | 27,8 | 40,0 |
| žádná | rbf | žádná | 76,2 | 84,1 | 30,3 | 43,3 |
| replikace | rbf | žádná | 78,0 | 75,0 | 36,6 | 53,8 |
| replikace, cost matrix | rbf | žádná | 66,4 | 73,4 | 62,7 | 67,0 |
| replikace, cost matrix | rbf | Bayesovská | 91,0 | 86,8 | 82,2 | 86,4 |

Tabulka 6-2 Ukázka matice záměn: trénovací data

| | | Skutečná kategorie | | |
|-----------------------|-------|--------------------|--------------|----------------|
| | | Sleep | Wake | |
| Predikovaná kategorie | Sleep | 8841 | 717 | PPV 92,5 % |
| | Wake | 66 | 13083 | NPV 92,4 % |
| | | Se 99,26 % | Sp 94,9 % | Acc 96,55 % |

Tabulka 6-3 Ukázka matice záměn: testovací data

| | | Skutečná kategorie | | |
|-----------------------|-------|--------------------|---------------|----------------|
| | | Sleep | Wake | |
| Predikovaná kategorie | Sleep | 4335 | 939 | PPV 82,2 % |
| | Wake | 427 | 6150 | NPV 82,2 % |
| | | Se 91,03 % | Sp 86,75 % | Acc 88,47 % |


Tabulka 6-4 Přehled průměrných výsledků na testovacích a trénovacích datech

| | Senzitivita | Specificita | Přesnost | PPV | NPV | F1 skóre |
|---------------|-------------|-------------|----------|-------|-------|----------|
| Trénovací [%] | 99,17 | 94,61 | 96,43 | 92,47 | 92,38 | 95,7 |
| Testovací [%] | 88,93 | 87,2 | 87,92 | 81,97 | 81,98 | 85,28 |

6.2 Klasifikace fází Wake, REM a NREM

Přístup ke klasifikaci dat do tří kategorií, a to Wake, REM a NREM spánek byl stejný jako klasifikace pouze do dvou fází. Velmi výrazně převažovala data z NREM fáze, která tvořila cca 70 % záznamu každého pacienta. Bdění a REM spánek byl zastoupen u všech zhruba přibližně, obě fáze v rozmezí 10-20 %. Proto bylo opět přistoupeno k replikaci dat s přidáním šumu v kategoriích Wake i REM. Testován byl také vliv cost matrix, který byl vysvětlen v předchozí kapitole. Průběžné trénování ukázalo, že model nejčastěji zaměňuje NREM a REM fázi či Wake a REM fázi. Záleželo na nastavení modelu, model však nebyl schopný zároveň správně detekovat Wake a REM fázi, pokud správně detekoval Wake, úspěšnost detekce REM fáze se výrazně snížila a naopak. Pro rozlišení fází byla opět využita kombinace replikace a matice ztrát, která vykazovala nejlepší výsledky a také radiální bazové jádro. Protože nejméně dat obsahovala kategorie Wake, byla matice ztrát nastavena tak, aby chybná klasifikace NREM či REM fáze měla větší váhu při výpočtu chyby, a to $1,2\times$.

Při trénování modelu byla data opět rozdělena v poměru cca 70:30. Trénování probíhalo tak, že vždy byly dvě kategorie dat porovnávány proti sobě a třetí byla ignorována. Takto se všechny kombinace prostrídaly. Trénování tohoto modelu opět probíhalo v cyklech formou křížové validace, aby nedocházelo k překrývání dat z trénovací a testovací množiny. I tento model prošel Bayesovskou optimalizací pro výběr nejlepších hyperparametrů modelu, kdy se model snažil nastavit optimální šířku tolerančního pásma a velikost parametru gamma minimalizací kritériální funkce (Obr. 6-5).



Obr. 6-5 Průběh minimalizace kritériální funkce

Vyhodnocení úspěšnosti modelu opět proběhlo pomocí matice záměn (Obr. 6-6). Počítány byly parametry senzitivita, specifická, PPV pro všechny kategorie zvlášť a poté celková přesnost modelu. Celková přesnost modelu byla 63,1 % pro trénovací data a

58,9 % pro testovací data. Výsledné parametry pro jednotlivé fáze jsou shrnuty v následujících tabulkách (Tabulka 6-5, Tabulka 6-6, Tabulka 6-7).

| | | Skutečná kategorie | | | |
|-----------------------|------|------------------------------|-------------------------------|------------------------------|----------|
| | | W | NREM | REM | |
| Predikovaná kategorie | W | Správně predikováno jako W | Chybně predikováno jako W | Chybně predikováno jako W | PPV W |
| | NREM | Chybně predikováno jako NREM | Správně predikováno jako NREM | Chybně predikováno jako NREM | PPV NREM |
| | REM | Chybně predikováno jako REM | Chybně predikováno jako REM | Správně predikováno jako REM | PPV REM |
| | | Senzitivita W | Senzitivita NREM | Senzitivita REM | Přesnost |

Obr. 6-6 Matice záměn pro tři kategorie

Tabulka 6-5 Přehled průměrných výsledků na testovacích a trénovacích datech, šířka pásma = 10, gama = 1,35

| Fáze | Množina dat | Senzitivita [%] | Specifická [%] | F1 skóre [%] |
|------|-------------|-----------------|----------------|--------------|
| Wake | Trénovací | 83,2 | 83,9 | 53,9 |
| | Testovací | 70,0 | 80,0 | 42,0 |
| REM | Trénovací | 57,9 | 74,7 | 61,8 |
| | Testovací | 54,3 | 68,6 | 57,9 |
| NREM | Trénovací | 64,0 | 72,2 | 67,1 |
| | Testovací | 61,0 | 68,6 | 64,7 |

Tabulka 6-6 Ukázka matice záměn: Trénovací data

| | | Skutečná kategorie | | |
|-----------------------|------|--------------------|-------------------|-----------------------|
| | | Wake | NREM | REM |
| Predikovaná kategorie | Wake | 1666 | 1007 | 1659 |
| | NREM | 190 | 7582 | 3006 |
| | REM | 140 | 3306 | 5857 |
| | | Se W 83,5 % | Se NREM 63,8 % | Se REM 55,7 % |
| | | | | PPV W 38,5 % |
| | | | | PPV NREM 70,4 % |
| | | | | PPV REM 63,0 % |
| | | | | Acc 61,9 % |

Tabulka 6-7 Ukázka matice záměn: Testovací data

| | | Skutečná kategorie | | |
|-----------------------|------|--------------------|-------------------|-----------------------|
| | | Wake | NREM | REM |
| Predikovaná kategorie | Wake | 709 | 816 | 735 |
| | NREM | 83 | 2884 | 1183 |
| | REM | 145 | 1007 | 2772 |
| | | Se W 75,7 % | Se NREM 61,3 % | Se REM 59,1 % |
| | | | | PPV W 31,4 % |
| | | | | PPV NREM 69,5 % |
| | | | | PPV REM 63,0 % |
| | | | | Acc 61,6 % |

6.2.1 Klasifikace fází Wake, REM a NREM metodou resubstituce

Kromě metody křížové validace, kdy se model učí na skupině dat a poté je otestován na jiné skupině, existují i další metody trénování a testování modelu. Mezi ně patří i metoda resubstituce, kdy model je natrénován na všech dostupných datech. Tato metoda byla vyzkoušena z toho důvodu, že trénování v rámci křížové validace probíhalo na relativně malém počtu dat. Účelem tohoto trénování bylo zjistit, jestli se zlepší parametry modelu, jako jsou přesnost, senzitivita, specifická aj., pokud bude model natrénován na celé množině dat. Ověření modelu by mělo proběhnout na nových nezávislých datech, taková bohužel nebyla k dispozici.

Matice ztrát i hyperparametry byly nastaveny stejně jako v předchozím modelu. Opět byla vyhodnocena matice záměn (Tabulka 6-8). Přehled výsledků obsahuje Tabulka 6-9.

Tabulka 6-8 Matice záměn resubstituční metody

| | | Skutečná kategorie | | | |
|-----------------------|------|--------------------|-------------------|------------------|--------------------|
| | | Wake | NREM | REM | |
| Predikovaná kategorie | Wake | 3224 | 1704 | 2040 | PPV W 46,3 % |
| | NREM | 423 | 10 812 | 4313 | PPV NREM 69,5 % |
| | REM | 469 | 4391 | 9057 | PPV REM 65,1 % |
| | | Se W 78,3 % | Se NREM 64,0 % | Se REM 58,8 % | Acc 63,4 % |

Tabulka 6-9 Přehled výsledků

| Fáze | Senzitivita [%] | Specifická [%] | F1 skóre [%] |
|------|-----------------|----------------|--------------|
| Wake | 78,3 | 84,1 | 58,2 |
| REM | 58,8 | 74,3 | 61,8 |
| NREM | 64,0 | 72,2 | 66,6 |

Můžeme vidět, že došlo k navýšení všech parametrů u všech fází, což se dalo předpokládat. Otázkou zůstává, zda by model dostatečně dobře reagoval na nová data.

Tabulka 6-10 Srovnání výsledků s literaturou

| Publikace | Snímané signály | Klasifikované fáze | Metoda klasifikace | Výsledky |
|---------------------------|---------------------------------------|-------------------------|-------------------------------------|--|
| navržená metoda | akcelerometr | W/S | SVM | Se: 88,9 % Sp: 87,2 % F1: 86,4 % |
| | | W/NREM/ REM | | Se W: 70,0 % Se NREM: 61,0 % Se REM: 54,3 % |
| Sundararajan et al., [37] | akcelerometr | W/S | náhodný les | F1: 73,9 % |
| Beattie et al., [38] | akcelerometr, PPG | W/S | neuronová síť | Se: 94,6 % Sp: 69,3 % |
| Aktaruzzaman et al., [39] | akcelerometr (zápěstí a hrudník), EKG | W/S | SVM | Se: 81 % Sp: 54 % |
| De Zambotti et al., [11] | akcelerometr, PPG, teplota, | W/NREM1+2/ NREM3/REM | patentovaný algoritmus OURA prstenu | Senzitivita: W: 48 % NREM1+2: 65 % NREM3: 51 % REM: 61 % |
| Walsch et al., [6] | akcelerometr, PPG | W/NREM/ REM | neuronová síť | Přesnost: W: 60 % REM: 62 % NREM: 62 % |


7. HODNOCENÍ KVALITY SPÁNKU

Tato kapitola je věnována srovnání vyhodnocení spánku jednotlivých pacientů modelem a expertem. V obou podkapitolách budou hodnoceny parametry celkový čas spánku (TST), celkový čas vzhůru (TWT), celkový čas záznamu (TRT), efektivita spánku (SE), probuzení po počátku spánku (WASO) a zpoždění spánku (Sleep latency). V podkapitole, která se věnuje hodnocení výstupů z vícekategoriálního SVM bude navíc vyhodnoceno i procento REM spánku a zpoždění REM spánku. [5]

7.1 Hodnocení výstupů z klasifikace Wake a Sleep

Výstup z modelu SVM dosahoval přesnosti přes 80 %, proto i na sloupcových grafech je patrné, že výsledky modelu a spánkového experta se v počítaných parametrech nijak výrazněji neliší. Výsledky byly vyhodnocovány na datech z jednoho cyklu křížové validace, tudíž grafy obsahují pacienty z testovací i trénovací skupiny. Pacienti z testovací skupiny jsou označeni kroužkem.


Jako první byl vypočítán parametr TST (Obr. 7-1). Z obrázku je patrné, že i když délka spánku odhadnutá expertem a modelem se výrazně neliší, model u většiny pacientů spánek nadhodnocuje, a to přibližně o 20 minut. Nejvyšší rozdíl můžeme vidět u pacienta č.11, kdy došlo k nadhodnocení spánku o cca 60 minut. Tento pacient pochází z testovací skupiny, ale celkově nemůžeme říct, že by model klasifikoval pacienty z testovací skupiny výrazně hůře než ty z trénovací. Celková odchylka modelu od hodnocení experta je cca 5,6 %, pouze na testovacích datech pak 8,7 %.



Obr. 7-1 Srovnání parametru TST vypočítaného z dat hodnocených expertem a výstupu modelu


Nadhodnocení spánku je obecným problémem nositelné elektroniky, což ukazuje i studie *Accuracy of Wristband Fitbit Models in Assessing Sleep* [35]. Důvodem je to, že pokud jsme při usínání v klidu, může být tato část modelem označena jako spánek.

Co se týče parametru TWT (Obr. 7-2), můžeme vidět malé podhodnocení času (průměrně 17,5 minut), kdy byl pacient vzhůru, což vyplývá i z hodnot parametru TST. Nejvyšší hodnoty můžeme vidět u pacienta č. 16, který byl téměř po celou dobu vyšetření vzhůru. Ani tento parametr se na testovacích datech výrazně nelišil.




Obr. 7-2 Srovnání parametru TWT vypočítaného z dat hodnocených expertem a výstupu modelu

Parametr WASO (Obr. 7-3) vyjadřuje čas, kdy byl pacient vzhůru po prvním usnutí. Tento parametr je počítán u lidí, kteří mají problém s přerušovaným spánkem. Může se to týkat lidí, kteří trpí právě různými poruchami, jako je spánková apnoe, insomnie, syndrom neklidných nohou apod. Parametr WASO určený modelem je oproti hodnotám spočítaným expertem u většiny pacientů nadhodnocený. Ze všech spočtených parametrů v něm můžeme vidět největší rozdíly, a to zejména u pacienta č. 18. Důvodem, proč model označil větší množství epoch jako bdění, jsou pohybové artefakty v NREM fázi. Průměrná hodnota nadhodnocení parametru je 18 minut, u testovacích dat pak 33 minut.




Obr. 7-3 Srovnání parametru WASO vypočítaného z dat hodnocených expertem a výstupu modelu

Výpočet efektivity spánku dosahuje také dobrých výsledků v porovnání s daty hodnocenými expertem (Obr. 7-4). Z důvodu, že model nadhodnocuje délku spánku, nadhodnocuje i jeho efektivitu. Efektivita odhadnutá modelem se oproti efektivitě odhadnuté expertem liší o 5,6 %. Tento parametr hraje velkou roli v diagnostice nespavosti a jeho zvýšení je zlatým standardem pro hodnocení úspěšnosti její léčby [36].



Obr. 7-4 Srovnání parametru SE vypočítaného z dat hodnocených expertem a výstupu modelu


Pro ukázkou klasifikace byl vykreslen hypnogram (Obr. 7-5), který srovnává data klasifikovaná expertem a data klasifikovaná modelem. Fáze 0 značí bdělost a fáze 1 značí spánek. Byl vybrán úsek z počátku měření, kdy pacient usíná, jelikož je na hypnogramu vidět, jak je model schopný reagovat na změny stavu. Na hypnogramu můžeme vidět obě typy chyb – záměnu Wake za Sleep i naopak.




Obr. 7-5 Hypnogram porovnávající výstupy experta a modelu (0 – Wake, 1 – Sleep)

7.2 Hodnocení výstupů z klasifikace Wake, REM a NREM

Parametr TST (Obr. 7-6) spočítaný z výstupu modelu je u většiny pacientů srovnatelný s hodnotou spočítanou z dat ohodnocenými expertem. I když úspěšnost modelu pro klasifikaci dat do tří kategorií byla výrazně nižší, z matice záměn (Tabulka 6-6) je patrné, že velmi často docházelo právě k záměnám REM fáze za NREM fázi, což na tento parametr nemá vliv. Daleko méně docházelo k záměnám bdění za NREM fázi. Rozdíl v parametru je tak způsoben převážně tím, že model má problém rozeznávat REM fázi od bdění. Můžeme vidět, že model délku spánku lehce nadhodnocuje, stejně jako model pro klasifikaci dat do dvou kategorií. Jedná se průměrně o 50 minut. U pacientů, kteří spadají do testovací skupiny je tento parametr shodný.



Obr. 7-6 Srovnání parametru TST vypočítaného z dat hodnocených expertem a výstupu modelu




Obr. 7-7 Srovnání parametru TWT vypočítaného z dat hodnocených expertem a výstupu modelu


Co se týče parametru TWT (Obr. 7-7), můžeme vidět, že model jeho hodnoty u velké části pacientů velmi podhodnocuje, což je způsobeno převážně nepřesností modelu při klasifikaci bdění, kterou velmi často zaměňuje za REM fázi. V matici záměn (Tabulka 6-6) můžeme vidět, že dochází k záměně více než poloviny epoch, kdy byl pacient vzhůru

za epochy REM a NREM, čemu odpovídá i průměrná odchylka modelu od dat ohodnocených expertem. Ta nabývá hodnoty 57 %. U testovacích dat je odchylka 55 %.

Podobně jako parametr TWT dopadl i parametr WASO (Obr. 7-8).




Obr. 7-8 Srovnání parametru WASO vypočítaného z dat hodnocených expertem a výstupu modelu



Obr. 7-9 Srovnání parametru SE vypočítaného z dat hodnocených expertem a výstupu modelu

U parametru SE (Obr. 7-9) také můžeme vidět nadhodnocení ze strany modelu, což vyplývá už z parametrů TST a TWT. Model se mýlil průměrně o 22 %, na testovacích datech pak o 17 %.




Obr. 7-10 Srovnání procenta REM spánku vypočítaného z dat hodnocených expertem a výstupu modelu

Dále bylo spočítáno procento REM fáze (Obr. 7-10). U zdravého dospělého člověka by se její procento mělo pohybovat někde mezi 20 a 25 %. S věkem toto procento klesá. Snížení tohoto procenta je příčinou spánkové deprivace. I když měl model problém odlišit REM fázi, ve výsledném parametru se to neprojevuje v tak velké míře. Je to z toho důvodu, že model zaměnil zhruba stejné množství epoch z REM fáze za NREM fázi a naopak. Rozdíl v parametru tak tvoří převážně REM epochy označené jako bdění. Odchylka modelu od dat experta nabyla téměř 46 %, na testovacích datech se pak jednalo o 38 %.


Pro klasifikaci epoch do tří kategorií byl také vykreslen hypnogram (Obr. 7-11). Tento graf vyjadřuje část spánku pacienta č.1. U pacienta byla nadhodnocena délka spánku i procento REM fáze. Podhodnocen byl čas vzhůru. Na vybraném úseku může pozorovat právě zaměňování NREM fáze za REM fázi a velmi časté zaměňování bdění za REM fázi.

Pro diagnostiku spánkových poruch je důležité, aby docházelo k co nejmenšímu nadhodnocení či podhodnocení parametrů, které na ně ukazují. Např. špatná detekce probuzení po počátku spánku (parametr WASO) může zakrýt problémy s přerušovaným

spánkem. Nadhodnocení REM spánku, což byl i problém vytvořeného modelu, může zakrýt jeho úbytek, který může být příčinou spánkové deprivace.



Obr. 7-11 Hypnogram porovnávající výstupy experta a modelu, (0 – Wake, 1 – NREM, 2 – REM)




Obr. 7-12 Graf TF a pohybu na stejném úseku jako předchozí hypnogram

Na stejném úseku, jako byl vykreslen hypnogram, byl vykreslen i graf tepové frekvence a pohybu (Obr. 7-12) pro analýzu chybových úseků modelu. Můžeme vidět, že těsně před počátkem REM fáze došlo ke zvýšení tepové frekvence a také k pohybu pacienta. V tomto úseku má model problém klasifikovat epochy jako NREM fázi a mění ji za REM i za Wake. REM fáze končí cca na 1,8 hod od začátku spánku. Můžeme vidět,

že model ještě část epoch zařazuje jako REM, pravděpodobně z důvodu většího rozptylu tepové frekvence.

7.3 Hodnocení výstupů modelu využívajícího resubstituci


I z modelu, který byl trénován a testován na stejné množině dat byly spočítány parametry popisující spánek. U parametru TST (Obr. 7-13) můžeme vidět, že model tolik nenadhodnocuje spánek. I odchylka od dat ohodnocených expertem se snížila, a to o 2 %.




Obr. 7-13 Srovnání parametru TST vypočítaného z dat hodnocených expertem a výstupu modelu

U parametru TWT (Obr. 7-14) můžeme vidět podobné podhodnocování ze strany modelu jako v předchozím případě. V tomto případě došlo naopak ke zhoršení výsledků modelu, konkrétně o 10 %.


Naopak k výraznému snížení odchylky (cca trojnásobně) od dat hodnocených expertem došlo i u parametru WASO (Obr. 7-15), což je pravděpodobně způsobeno zvýšením PPV při klasifikaci bdění.



Obr. 7-14 Srovnání parametru TWT vypočítaného z dat hodnocených expertem a výstupu modelu




Obr. 7-15 Srovnání parametru WASO vypočítaného z dat hodnocených expertem a výstupu modelu



Obr. 7-16 Srovnání parametru SE vypočítaného z dat hodnocených expertem a výstupu modelu

Jelikož se zlepšil parametr TST, ke zlepšení odhadu došlo i v případě parametru SE (Obr. 7-16). Odchylka od výstupů experta klesla na 4 %.



Obr. 7-17 Srovnání zastoupení REM spánku vypočítaného z dat hodnocených expertem a výstupu modelu

Co se týče zastoupení REM spánku (Obr. 7-17), oproti předchozímu modelu došlo k výraznému zhoršení tohoto parametru. Odchylka několikanásobně vzrostla, a to až o 100 %.

Přesnost tohoto modelu se dala srovnat s přesností přechozího modelu na trénovacích datech. Oproti předchozímu modelu lépe klasifikuje bdění, avšak na úkor přesnosti klasifikace REM fáze.

ZÁVĚR

Prvním cílem této práce bylo provést literární rešerši v oblasti spánku a jeho měření, seznámit se s klasickými i moderními přístupy pro jeho detekci i klasifikaci a představit metriky, které se používají pro stanovení kvality spánku. První kapitola se zabývá fyziologií spánku, jednotlivými spánkovými fázemi a taky jeho základními poruchami. Právě kvůli těmto poruchám je důležité umět spánek změřit a správně ho klasifikovat. Jeho měření se věnuje kapitola č. 2, která představuje jak klasickou metodu monitorace spánku – PSG, tak i alternativní a dnes se velmi rychle rozvíjející metodu aktigrafie, která k monitoraci spánku využívá chytrá zařízení, jako jsou hodinky či prsteny. Poslední kapitola, která spadá do literární rešerše se zabývá metodami strojového učení, které umožňují automatickou klasifikaci spánkových fází.

Druhým cílem práce bylo navrhnout algoritmus, který zpracuje libovolné signály naměřené pomocí chytrých hodinek a vytvoří matici příznaků, která bude využita k trénování modelu. Signály, které byly použity, pochází z databáze *Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device* [6], která je volně dostupná. Tato databáze obsahovala signál tepové frekvence a signál z akcelerometru od více než 30 pacientů. Pacienti zároveň podstoupili také PSG vyšetření, která byla vyhodnocena expertem a přiložena k databázi. Na těchto datech byl pak učen model.

Učení modelu předcházelo extrahování matice příznaků z poskytnutých dat o tepové frekvenci a pohybu pacienta. Příznaky byly vybrány pomocí statistického testování. Pro automatickou klasifikaci spánkových epoch pak byla vybrána metoda podpůrných vektorů pro její jednoduchost a dobré výsledky v předchozích studiích. Nejdříve byly epochy rozděleny pouze na bdění a spánek, a poté i na bdění, REM a NREM fázi. Učení modelu probíhalo cestou křížové validace.

Při klasifikaci epoch pouze na bdění a spánek model dosahoval dobrých výsledků kdy jeho senzitivita, specifita i F1 skóre přesáhly hranici 85 %. Z výstupu modelu i dat ohodnocených expertem byly vypočítány parametry hodnotící kvalitu spánku. Nejvyšší rozdíl od dat hodnocených expertem vykazoval parametr WASO (16 %).

Při klasifikaci epoch na bdění, REM a NREM spánek měl model problémy rozlišit jak bdění od REM, tak i REM od NREM fáze. Senzitivita klasifikace fáze bdění dosáhla hodnoty 70 % a specifita 80 %, F1 skóre však zůstalo pouze na 42 %. Senzitivita REM fáze přesáhla 54 %, specifita 68 % a F1 skóre 57 %. Senzitivita NREM fáze pak dosáhla 61 %, specifita 68 % a F1 skóre 64 %. I když výsledky tohoto modelu nebyly dostatečně kvalitní, parametry TST a efektivita spánku byly odhadnuty s odchylkou 20 %. Proti klasifikaci epoch do dvou fází bylo navíc spočítáno procento REM fáze ve spánku. Parametr vypočítaný z výstupu modelu se lišil od dat ohodnocených expertem v průměru

o 46 %. Nejhorší dopadly parametry TWT a WASO, a to z důvodu častého zaměňování REM fáze za bdění.

Co se týče modelu využívajícího resubstituci, došlo ke zlepšení rozpoznávání bdění na úkor rozpoznávání REM fáze. Celková přesnost zůstala téměř stejná, u předchozího modelu byla přesnost na trénovacích datech pouze o jedno procento vyšší, na testovacích datech naopak o 5 % nižší. Otázkou zůstává, jak dobře by model reagoval na nová data.

Pro zpřesnění výsledků by bylo vhodné využít další signály, které mohou být měřeny pomocí chytré elektroniky. Volba by mohla padnout např. na tělesnou teplotu, která během dne kolísá a ve spánku může být nižší. Tuto možnost nabízí např. ŌURA prsten. Tento prsten umí zachytit i dechovou frekvenci, která by také mohla pomoci k přesnější klasifikaci. Otázkou je v tomto případě i vliv umístění senzoru, kdy snímač umístěný na prstu by podle článku *The Oura Difference* [40] měl dosahovat vyšší přesnosti, jelikož měří v cévách prstu, zatímco většina dostupných chytrých hodinek měří signály z povrchu těla. Další možností zpřesnění klasifikace je zvětšení trénovací množiny dat, tedy získat data od více pacientů.

Literatura

- [1] ROKYTA, Richard. Fyziologie. Třetí přepracované vydání. Praha: Galén, 2016. ISBN 978-80-7492-238-1.
- [2] Sleep Disorders. In: Sleep Foundation [online]. [cit. 2020-11-25]. Dostupné z: <https://www.sleepfoundation.org/sleep-disorders>
- [3] SMITH, Anna Karla a Sônia Maria GUIMARÃES PEREIRA TOGEIRO. Diagnostics methods for sleep disorders. Revista Brasileira de Psiquiatria [online]. 2005, (27) [cit. 2020-11-25]. Dostupné z: <https://europepmc.org/article/med/16082449>
- [4] FERNÁNDEZ-LEAL, Angél, Mariano CABRERO-CANOSA, Eduardo MOSQUEIRA-REY a Vincente MORET-BONILLO. A knowledge model for the development of a framework for hypnogram construction. Knowledge-Based Systems [online]. 2017, (118), 12 [cit. 2020-11-23]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0950705116304737>
- [5] MORÁŇ, Miroslav. *Fakultní nemocnice Brno* [online]. [cit. 2020-11-25]. Dostupné z: <https://www.fnbrno.cz/poruchy-spanku/t3729>
- [6] WALCH, Olivia, Yitong HUANG, Daniel FORGER a Cathy GOLDSTEIN. Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device. Sleep [online]. 2019, 42(12), 1-19 [cit. 2020-11-23]. Dostupné z: <https://academic.oup.com/sleep/article/42/12/zsz180/5549536>
- [7] MARINO, Miguel, Yi LI, Michael RUESCHMAN, et al. Measuring Sleep: Accuracy, Sensitivity, and Specificity of Wrist Actigraphy Compared to Polysomnography. Sleep [online]. 2013, 36(11), 8 [cit. 2020-12-19]. Dostupné z: <https://academic.oup.com/sleep/article/36/11/1747/2558963?login=true>
- [8] MOOR, Zaswiza Mohamad, Alesha J. SMITH, Simon S. SMITH a Lisa M. NISSEN. A feasibility study: Use of actigraph to monitor and follow-up sleep/wake patterns in individuals attending community pharmacy with sleeping disorders. Journal of Sciences & BioAllied Sciences [online]. 2016, 3(8), 9 [cit. 2020-11-25]. Dostupné z: https://www.researchgate.net/publication/287157119_A_feasibility_study_Use_of_actigraph_to_monitor_and_follow-up_sleepwake_patterns_in_individuals_attending_community_pharmacy_with_sleeping_disorders
- [9] PENZEL, Thomas, Jan W KANTELHARDT, Chung-Chang LO, Karlheinz VOIGT a Claus VOGELMEIER. Dynamics of Heart Rate and Sleep Stages in Normals and Patients with Sleep Apnea. Neuropsychopharmacology [online]. 2003, 28(S1), S48-S53 [cit. 2020-12-20]. ISSN 0893-133X. Dostupné z: [doi:10.1038/sj.npp.1300146](https://doi.org/10.1038/sj.npp.1300146)

- [10] HAGHAYEGH, Shahab, Sepideh KHOSHNEVIS, Michael H. SMOLENSKY, Kenneth R. DILLER a Richard J. CASTRIOTTA. Accuracy of Wristband Fitbit Models in Assessing Sleep: Systematic Review and Meta-Analysis. *Journal of Medical Internet Research* [online]. 2019 [cit. 2020-12-19]. Dostupné z: https://www.jmir.org/2019/11/e16273/?utm_source=dlvr.it&utm_medium=facebook
- [11] DE ZAMBOTTI, Massimiliano, Leonardo ROSAS, Ian M. COLRAIN a Fiona C. BAKER. The Sleep of the Ring: Comparison of the ŌURA Sleep Tracker Against Polysomnography. *Behavioral Sleep Medicine* [online]. 2017, 17(2), 124-136 [cit. 2020-12-19]. ISSN 1540-2002. Dostupné z: doi:10.1080/15402002.2017.1300587
- [12] CHRISKOS, Panteleimon, Dimitra S. KAITALIDOU, Georgios KARAKASIS, Christos FRANTZIDIS, Polyxeni T. GKIVOGKLI, Panagiotis BAMIDIS a Chrysoula KOURTIDOU-PAPADELI. Automatic Sleep Stage Classification Applying Machine Learning Algorithms on EEG Recordings. 2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS) [online]. IEEE, 2017, 2017, 435-439 [cit. 2020-12-19]. ISBN 978-1-5386-1710-6. Dostupné z: doi:10.1109/CBMS.2017.83
- [13] K-means Clustering: Algorithm, Applications, Evaluation Methods, and Drawbacks. *Towards Data Science* [online]. [cit. 2020-11-26]. Dostupné z: <https://towardsdatascience.com/k-means-clustering-algorithm-applications-evaluation-methods-and-drawbacks-aa03e644b48a>
- [14] PAGE, Justin T, Zachary S LIECHTY, Mark D HUYNH a Joshua A UDALL. BamBam: genome sequence analysis tools for biologists. *BMC Research Notes* [online]. 2014, 7(1) [cit. 2020-12-19]. ISSN 1756-0500. Dostupné z: doi:10.1186/1756-0500-7-829
- [15] VAN HESE, P., W. PHILIPS, J. DE KONINCK, R. VAN DE WALLE a I. LEMAHIEU. Automatic detection of sleep stages using the EEG. 2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society [online]. IEEE, 2001, , 1944-1947 [cit. 2020-12-29]. ISBN 0-7803-7211-5. Dostupné z: doi:10.1109/IEMBS.2001.1020608
- [16] KLOK, Aske B., Joakim EDIN, Matteo CESARI, Alexander Neergaard OLESEN, Poul JENNUM a Helge B.D. SORENSEN. A New Fully Automated Random-Forest Algorithm for Sleep Staging. 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) [online]. IEEE, 2018, 2018, , 4920-4923 [cit. 2020-12-29]. ISBN 978-1-5386-3646-6. Dostupné z: doi:10.1109/EMBC.2018.8513413
- [17] Matematický model a aktivní dynamika neuronu. *Matematická biologie* [online]. [cit. 2020-11-26]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--umela-inteligence--neuronove-site-jednotlivy-neuron--jednotlivy-neuron--matematicky-model-a-aktivni-dynamika-neuronu>

- [18] A Simple Multilayer Perceptron with TensorFlow [online]. [cit. 2020-11-26]. Dostupné z: <https://medium.com/pankajmathur/a-simple-multilayer-perceptron-with-tensorflow-3effe7bf3466>
- [19] Koncept umělé neuronové sítě. Matematická biologie [online]. [cit. 2020-11-26]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--umela-intelligence--neuronove-site-jednotlivy-neuron--uvod-do-neuronovych-siti--koncept-umele-neuronove-site>
- [20] SORS, Arnaud, Stéphane BONNET, Sébastien MIREK, Laurent VERCUEIL a Jean-François PAYEN. A convolutional neural network for sleep stage scoring from raw single-channel EEG. Biomedical Signal Processing and Control [online]. 2018, 42, 107-114 [cit. 2020-12-29]. ISSN 17468094. Dostupné z: doi:10.1016/j.bspc.2017.12.001
- [21] Lineární verze metody podpůrných vektorů – lineárně separabilní třídy. Matematická biologie [online]. [cit. 2020-11-26]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--vicerozmerne-metody-pro-analyzu-dat--klasifikace--klasifikace-pomoci-hranic-v-obrazovem-prostoru-flda-svm-linearni-a-nelinearni--metoda-podpurnych-vektoru--linearni-verze-metody-podpurnych-vektoru--linearne-separabilni-tridy>
- [22] Nelineární verze metody podpůrných vektorů. Matematická biologie [online]. [cit. 2020-11-26]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--vicerozmerne-metody-pro-analyzu-dat--klasifikace--klasifikace-pomoci-hranic-v-obrazovem-prostoru-flda-svm-linearni-a-nelinearni--metoda-podpurnych-vektoru--nelinearni-verze-metody-podpurnych-vektoru>
- [23] RHYS, Hefin. Machine Learning with R [online]. [cit. 2020-12-23]. Dostupné z: https://machinelearningwithmlr.files.wordpress.com/2019/10/ch06_fig_6_mlr.png?w=750
- [24] KEMPFNER, Jacob, Poul JENNUM, Helge B. D. SORENSEN, Julie A. E. CHRISTENSEN a Miki NIKOLIC. Automatic SLEEP staging: From young adults to elderly patients using multi-class support vector machine. 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) [online]. IEEE, 2013, 2013, , 5777-5780 [cit. 2020-12-29]. ISBN 978-1-4577-0216-7. Dostupné z: doi:10.1109/EMBC.2013.6610864
- [25] DIYKH, Mohammed, Yan LI a Peng WEN. EEG Sleep Stages Classification Based on Time Domain Features and Structural Graph Similarity. IEEE Transactions on Neural Systems and Rehabilitation Engineering [online]. 2016, 24(11), 1159-1168 [cit. 2020-12-29]. ISSN 1534-4320. Dostupné z: doi:10.1109/TNSRE.2016.2552539
- [26] KOLEY, B. a D. DEY. An ensemble system for automatic sleep stage classification using single channel EEG signal. Computers in Biology and

- Medicine [online]. 2012, 42(12), 1186-1195 [cit. 2020-12-29]. ISSN 00104825. Dostupné z: doi:10.1016/j.compbimed.2012.09.012
- [27] ALDREDGE, Joanne L a Ashley J WELCH. Variations of heart rate during sleep as a function of the sleep cycle. *Electroencephalography and Clinical Neurophysiology* [online]. 1973, 35(2), 193-198 [cit. 2020-12-30]. ISSN 00134694. Dostupné z: doi:10.1016/0013-4694(73)90176-4
- [28] CHARBONNIER, S., L. ZOUBEK, S. LESECQ a F. CHAPOTOT. Self-evaluated automatic classifier as a decision-support tool for sleep/wake staging. *Computers in Biology and Medicine* [online]. 2011, 41(6), 380-389 [cit. 2020-12-30]. ISSN 00104825. Dostupné z: doi:10.1016/j.compbimed.2011.04.001
- [29] ZOUBEK, Lukáš, Sylvie CHARBONNIER, Suzanne LESECQ, Alain BUGUET a Florian CHAPOTOT. Feature selection for sleep/wake stages classification using data driven methods. *Biomedical Signal Processing and Control* [online]. 2007, 2(3), 171-179 [cit. 2020-12-30]. ISSN 17468094. Dostupné z: doi:10.1016/j.bspc.2007.05.005
- [30] LAI, Ying-Chih, Chin-Chia CHANG, Chia-Ming TSAI, Shih-Ching HUANG a Kai-Wei CHIANG. A Knowledge-Based Step Length Estimation Method Based on Fuzzy Logic and Multi-Sensor Fusion Algorithms for a Pedestrian Dead Reckoning System. *ISPRS International Journal of Geo-Information* [online]. 2016, 5(5) [cit. 2021-03-07]. ISSN 2220-9964. Dostupné z: doi:10.3390/ijgi5050070
- [31] SUKOR, A. S. Abdull, A. ZAKARIA a N. Abdul RAHIM. Activity recognition using accelerometer sensor and machine learning classifiers [online]. *IEEE*, 2018, 2018, , 233-238 [cit. 2021-03-07]. ISBN 978-1-5386-0389-5. Dostupné z: doi:10.1109/CSPA.2018.8368718
- [32] BERSCH, Sebastian, Djamel AZZI, Rinat KHUSAINOV, Ifeyinwa ACHUMBA a Jana RIES. Sensor Data Acquisition and Processing Parameters for Human Activity Classification. *Sensors*. 2014, 14(3), 4239-4270. ISSN 1424-8220. Dostupné z: doi:10.3390/s140304239
- [33] CHOUEIRY, George. Square Root Transformation: A Beginner's Guide. *Quantifying Health* [online]. [cit. 2021-03-06]. Dostupné z: <https://quantifyinghealth.com/square-root-transformation/>
- [34] Neparametrická alternativa analýzy rozptylu – Kruskalův-Wallisův test. *Matematická biologie* [online]. [cit. 2020-12-30]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=aplikovana-analyza-klinickych-a-biologickych-dat--analyza-a-management-dat-pro-zdravotnicke-obory--analyza-rozptylu-anova--neparametricka-alternativa-analyzy-rozptylu-kruskaluv-wallisuv-test>
- [35] HAGHAYEGH, Shahab, Sepideh KHOSHNEVIS, Michael H SMOLENSKY, Kenneth R DILLER a Richard J CASTRIOTTA. Accuracy of Wristband Fitbit Models in Assessing Sleep: Systematic Review and Meta-Analysis. *Journal of*

- Medical Internet Research [online]. 2019, 21(11) [cit. 2021-04-04]. ISSN 1438-8871. Dostupné z: doi:10.2196/16273
- [36] REED, David L. a William P. SACCO. Measuring Sleep Efficiency: What Should the Denominator Be? *Journal of Clinical Sleep Medicine* [online]. 2016, 12(02), 263-266 [cit. 2021-04-04]. ISSN 1550-9389. Dostupné z: doi:10.5664/jcsm.5498
- [37] SUNDARARAJAN, Kalaivani, Sonja GEORGIEVSKA, Bart H. W. TE LINDERT, et al. Sleep classification from wrist-worn accelerometer data using random forests. *Scientific Reports* [online]. 2021, 11(1) [cit. 2021-04-07]. ISSN 2045-2322. Dostupné z: doi:10.1038/s41598-020-79217-x
- [38] BEATTIE, Z, Y OYANG, A STATAN, A GHOREYSHI, A PANTELOPOULOS, A RUSSELL a C HENEGHAN. Estimation of sleep stages in a healthy adult population from optical plethysmography and accelerometer signals. *Physiological Measurement* [online]. 2017, 38(11), 1968-1979 [cit. 2021-04-07]. ISSN 1361-6579. Dostupné z: doi:10.1088/1361-6579/aa9047
- [39] AKTARUZZAMAN, Md, Massimo Walter RIVOLTA, Ruby KARMACHARYA, et al. Performance comparison between wrist and chest actigraphy in combination with heart rate variability for sleep classification. *Computers in Biology and Medicine* [online]. 2017, 89, 212-221 [cit. 2021-04-07]. ISSN 00104825. Dostupné z: doi:10.1016/j.combiomed.2017.08.006
- [40] The Oura Difference. OURA [online]. [cit. 2021-5-14]. Dostupné z: <https://ouraring.com/blog/the-oura-difference/>